

ISSN 2713-3192
DOI 10.15622/ia.2026.25.1
<http://ia.spcras.ru>

ТОМ 25 № 1

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

INFORMATICS AND AUTOMATION



СПб ФИЦ РАН

Санкт-Петербург
2026



INFORMATICS AND AUTOMATION

Volume 25 № 1, 2026

Scientific and educational journal primarily specialized in computer science, automation, robotics, applied mathematics, interdisciplinary research

Founded in 2002

Founder and Publisher

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)

Editor-in-Chief

A. L. Ronzhin, Prof., Dr. Sci., St. Petersburg, Russia

Editorial Council

A. A. Ashimov	Prof., Dr. Sci., Academician of the National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan
I. A. Kalyaev	Prof., Dr. Sci., Academician of RAS, Taganrog, Russia
A. I. Rudskoi	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
V. Sgurev	Prof., Dr. Sci., Academician of the Bulgarian Academy of Sciences, Sofia, Bulgaria
B. Ya. Sovetov	Prof., Dr. Sci., Academician of RAE, St. Petersburg, Russia
V. A. Soyfer	Prof., Dr. Sci., Academician of RAS, Samara, Russia

Editorial Board

E. Azarov	Prof., Dr.Sci., Minsk, Belarus
O. Yu. Gusikhin	Ph. D., Dearborn, USA
V. Delic	Prof., Dr. Sci., Novi Sad, Serbia
A. Dolgui	Prof., Dr. Sci., St. Etienne, France
M. N. Favorskaya	Prof., Dr. Sci., Krasnoyarsk, Russia
M. Zelezny	Assoc. Prof., Ph.D., Plzen, Czech Republic
H. Kaya	Assoc. Prof., Ph.D., Utrecht, Netherlands
A. A. Karpov	Assoc. Prof., Dr. Sci., St. Petersburg, Russia
S. V. Kuleshov	Dr. Sci., St. Petersburg, Russia
A. D. Khomonenko	Prof., Dr. Sci., St. Petersburg, Russia
D. A. Ivanov	Prof., Dr. Habil., Berlin, Germany
K. P. Markov	Assoc. Prof., Ph.D., Aizu, Japan
R. V. Meshcheryakov	Prof., Dr. Sci., Moscow, Russia
N. A. Moldovian	Prof., Dr. Sci., St. Petersburg, Russia
V. V. Nikulin	Prof., Ph.D., New York, United States
V. Yu. Osipov	Prof., Dr. Sci., Deputy Editor-in-Chief, St. Petersburg, Russia
V. K. Pshikhopov	Prof., Dr. Sci., Taganrog, Russia
H. Samani	Assoc. Prof., Ph.D., Plymouth, UK
J. Savage	Assoc. Prof., Ph.D., Mexico City, Mexico
M. Secujski	Assoc. Prof., Ph.D., Novi Sad, Serbia
A. V. Smirnov	Prof., Dr. Sci., St. Petersburg, Russia
B. V. Sokolov	Prof., Dr. Sci., St. Petersburg, Russia
L. V. Utkin	Prof., Dr. Sci., St. Petersburg, Russia
L. B. Sheremetov	Assoc. Prof., Dr. Sci., Mexico, Mexico

Editor: A. S. Viktorova

Interpreter: Ya. N. Berezina

Art editor: N. A. Dormidontova

Editorial office address

SPC RAS, 39 litera A , 14-th line V.O., St. Petersburg, 199178, Russia

e-mail: ia@spcras.ru, web: <http://ia.spcras.ru>

The journal is indexed in Scopus

The journal is published under the scientific-methodological supervision of Department for Nanotechnologies and Information Technologies of the Russian Academy of Sciences

© St. Petersburg Federal Research Center of the Russian Academy of Sciences, 2025

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 25 № 1, 2026

Научный, научно-образовательный журнал с базовой специализацией
в области информатики, автоматизации, робототехники, прикладной математики
и междисциплинарных исследований.

Журнал основан в 2002 году

Учредитель и издатель

Федеральное государственное бюджетное учреждение науки
«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук»
(СПб ФИЦ РАН)

Главный редактор

А. Л. Ронжин, д-р техн. наук, проф., Санкт-Петербург, РФ

Редакционный совет

А. А. Ашимов	академик Национальной академии наук Республики Казахстан, д-р техн. наук, проф., Алматы, Казахстан
И. А. Каляев	академик РАН, д-р техн. наук, проф., Таганрог, РФ
А. И. Рудской	академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ
В. Струев	академик Болгарской академии наук, д-р техн. наук, проф., София, Болгария
Б. Я. Советов	академик РАО, д-р техн. наук, проф., Санкт-Петербург, РФ
В. А. Сойфер	академик РАН, д-р техн. наук, проф., Самара, РФ

Редакционная коллегия

И. С. Азаров	д-р техн. наук, проф., Минск, Беларусь
О. Ю. Гусихин	д-р наук, Диаборн, США
В. Делич	д-р техн. наук, проф., Нови-Сад, Сербия
А. Б. Долгий	д-р наук, проф., Сент-Этьен, Франция
М. Железны	д-р наук, доцент, Пльзень, Чешская Республика
Д. А. Иванов	д-р экон. наук, проф., Берлин, Германия
Х. Кайя	д-р наук, доцент, Уtrecht, Нидерланды
А. А. Карпов	д-р техн. наук, доцент, Санкт-Петербург, РФ
С. В. Кулешов	д-р техн. наук, Санкт-Петербург, РФ
К. П. Марков	д-р наук, доцент, Аизу, Япония
Р. В. Мещеряков	д-р техн. наук, проф., Москва, РФ
Н. А. Молодянин	д-р техн. наук, проф., Санкт-Петербург, РФ
В. В. Никулин	д-р наук, проф., Нью-Йорк, США
В.Ю. Осипов	д-р техн. наук, проф., зам. главного редактора, Санкт-Петербург, РФ
В. Х. Пшихопов	д-р техн. наук, проф., Таганрог, РФ
Х. К. Савак	д-р техн. наук, доцент, Мехико, Мексика
Х. Самани	д-р наук, доцент, Плимут, Соединённое Королевство
М. Сечуйски	д-р техн. наук, доцент, Нови-Сад, Сербия
А. В. Смирнов	д-р техн. наук, проф., Санкт-Петербург, РФ
Б. В. Соколов	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. В. Уткин	д-р техн. наук, проф., Санкт-Петербург, РФ
М. Н. Фаворская	д-р техн. наук, проф., Красноярск, РФ
А. Д. Хомоненко	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. Б. Шереметов	д-р техн. наук, Мехико, Мексика

Выпускающий редактор: А. С. Викторова

Переводчик: Я. Н. Березина

Художественный редактор: Н. А. Дормидонтова

Адрес редакции

14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

e-mail: ia@spcras.ru, сайт: <http://ia.spcras.ru>

Журнал индексируется в международной базе данных Scopus

Журнал входит в «Перечень ведущих рецензируемых научных журналов и изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени доктора и кандидата наук»

Журнал выпускается при научно-методическом руководстве Отделения нанотехнологий и информационных технологий Российской академии наук

© Федеральное государственное бюджетное учреждение науки

«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук», 2025
Разрешается воспроизведение в прессе, а также сообщение в эфир или по кабелю опубликованных
в составе печатного периодического издания - журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»
статьей по текущим экономическим, политическим, социальным и религиозным вопросам
с обязательным указанием имени автора статьи и печатного периодического издания
журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»

CONTENTS

Towards 75th Anniversary of Boris V. Sokolov	5
Robotics, Automation and Control Systems	
P. Plotnikov, G. Tambovtsev, A. Vladko	
MATHEMATICAL MODEL OF MULTI-CRITERIA BALANCING OF V2X-SYSTEM PARAMETERS	16
A. Akimov, Yu. Gnatenco, R. Bolbakov	
A MULTI-LAYER STRATEGY FOR SAFE NAVIGATION AND SWARM DISTRIBUTION OF UAVS IN WILDFIRE MONITORING	49
Information Security	
V. Krundyshev, M. Kalinin	
EVALUATION OF INFORMATION SECURITY EFFICIENCY IN SMART CITY SYSTEMS BASED ON A COMPETITION MODEL	80
A. Rajeev, Raviraj P.	
SPATIOTEMPORAL AND BEHAVIORAL FEATURE-AWARE MODEL WITH XCEPTIONCAPSULE FUSION FOR DEEPFAKE DETECTION	110
Artificial Intelligence, Knowledge and Data Engineering	
Iu. Lezhenin, N. Bogach	
AN INPUT-SYNCHRONOUS BLOCKWISE DECODING ALGORITHM FOR CTC-AED SPEECH RECOGNITION	153
N. Kolmakov, A. Golubinskiy	
ASSESSING THE INFLUENCE OF FLOATING-POINT BIT DEPTH ON SPEAKER RECOGNITION ACCURACY	176
V. Chertkov, R. Bohush, Y. Adamovskiy, V. Rogulev	
SIMULATION MODEL OF COGNITIVE RADIO	200
I. Filianin, A. Kapitonov, A. Timoshchuk-Bondar	
RESEARCH ON REINFORCEMENT LEARNING ALGORITHMS FOR NETWORK LATENCY REDUCTION IN EDGE COMPUTING	234
Conference Calendar	262

СОДЕРЖАНИЕ

К 75-летнему Юбилею Соколова Бориса Владимировича	5
Робототехника, автоматизация и системы управления	
П.В. Плотников, Г.И. Тамбовцев, А.Г. Владыко МАТЕМАТИЧЕСКАЯ МОДЕЛЬ МНОГОКРИТЕРИАЛЬНОЙ БАЛАНСИРОВКИ ПАРАМЕТРОВ V2X-СИСТЕМ	16
А.А. Акимов, Ю.А. Гнатенко, Р.Г. Болбаков МНОГОУРОВНЕВАЯ СТРАТЕГИЯ БЕЗОПАСНОЙ НАВИГАЦИИ И РАСПРЕДЕЛЕНИЯ РОЯ БПЛА ДЛЯ МОНИТОРИНГА ЛЕСНЫХ ПОЖАРОВ	49
Информационная безопасность	
В.М. Крундышев, М.О. Калинин ОЦЕНКА ЭФФЕКТИВНОСТИ ОБЕСПЕЧЕНИЯ ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ В СИСТЕМАХ УМНОГО ГОРОДА НА ОСНОВЕ МОДЕЛИ КОНКУРЕНЦИИ	80
А. Раджик, Равирадж П. МОДЕЛЬ ДЛЯ ОБНАРУЖЕНИЯ ДИФФЕЙКОВ С УЧЕТОМ ПРОСТРАНСТВЕННО- ВРЕМЕННЫХ И ПОВЕДЕНЧЕСКИХ ПРИЗНАКОВ НА ОСНОВЕ ОБЪЕДИНЕНИЯ ХСЕРPTIONCAPSULE	110
Искусственный интеллект, инженерия данных и знаний	
Ю.И. Леженин, Н.В. Богач БЛОЧНЫЙ АЛГОРИТМ ДЕКОДИРОВАНИЯ С СИНХРОНИЗАЦИЕЙ ПО ВХОДУ ДЛЯ СТС-АЕД СИСТЕМ РАСПОЗНАВАНИЯ РЕЧИ	153
Н.П. Колмаков, А.Н. Голубинский ОЦЕНКА ВЛИЯНИЯ БИТНОСТИ ЧИСЕЛ С ПЛАВАЮЩЕЙ ЗАПЯТОЙ НА ТОЧНОСТЬ РАСПОЗНАВАНИЯ ДИКТОРОВ	176
В.М. Чертков, Р.П. Богуш, Е.Р. Адамовский, В.С. Рогулев ИМИТАЦИОННАЯ МОДЕЛЬ КОГНИТИВНОГО РАДИО	200
И.В. Филиянин, А.А. Капитонов, А.И. Тимошук-Бондарь ИССЛЕДОВАНИЕ АЛГОРИТМОВ ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ ДЛЯ СНИЖЕНИЯ СЕТЕВОЙ ЗАДЕРЖКИ В ГРАНИЧНЫХ ВЫЧИСЛЕНИЯХ	234
Календарь конференций	262

К 75-ЛЕТНЕМУ ЮБИЛЕЮ СОКОЛОВА БОРИСА ВЛАДИМИРОВИЧА



В январе 2026 г. доктор технических наук, профессор Соколов Борис Владимирович отмечает 75-летний юбилей. Профессор Соколов Б.В. является широко известным в нашей стране и за ее пределами ученым, Заслуженным деятелем науки Российской Федерации, дважды Лауреатом премии Правительства РФ в области науки и техники, Лауреатом премии Правительства Санкт-Петербурга, Лауреатом Стипендии Президента РФ «За выдающиеся заслуги в области вооружения, военной и специальной техники», руководителем – главным научным сотрудником лаборатории информационных технологий в системном анализе и моделировании Санкт-Петербургского Федерального исследовательского центра Российской академии наук.

Соколов Борис Владимирович родился в Ленинграде. После окончания 8 классов 73 городской школы поступил в Ленинградское суворовское военное училище, которое закончил в 1969 г. В августе 1969 г. был принят слушателем Ленинградской военной инженерной Краснознаменной академии им. А.Ф. Можайского (ЛВИКА), которую закончил с отличием в 1974 по специальности «Баллистика и теория полета». С 1974 г. по 1978 г. служил в наземном автоматизированном комплексе управления космическими аппаратами. В 1978 г. поступил в очную адъюнктуру на кафедру «Автоматизированных систем управления космическими аппаратами» (кафедру № 62) Военного

инженерного Краснознаменного института им. А.Ф. Можайского (ВИКИ), которую закончил в 1981 г., и 20 мая 1982 г. защитил кандидатскую диссертацию. Далее проходил службу в ВИКИ им. А.Ф. Можайского на преподавательских и научных должностях. Здесь в мае 1992 г. защитил диссертацию на соискание ученой степени доктора технических наук, в 1994 г. ему присвоено ученое звание профессора. С мая 1992 г. по июнь 1998 г. являлся начальником своей родной кафедры «Автоматизированных систем управления космическими аппаратами». Военную службу закончил в воинском звании полковника.

После окончания военной службы основная трудовая и научная деятельность Бориса Владимировича связана с Санкт-Петербургским институтом информатики и автоматизации Российской академии наук, ныне – Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Здесь он трудился и продолжает трудиться на должностях ведущего научного сотрудника (1999-2006 гг.), заместителя директора по научной работе (2006-2017 гг.), руководителя лаборатории информационных технологий в системном анализе и моделировании – главного научного сотрудника (с 2017 г. по настоящее время).

Начало активной научно-педагогической деятельности Соколова Б.В. связано с обучением в адъюнктуре, с 1982 г. Однако тяга к точным наукам проявилась у Соколова Б.В. гораздо раньше благодаря талантливым педагогам, учителям математики: в школе – Кондрашову Игорю Васильевичу, в ЛенСВУ – Сократилиной Ирине Петровне, впоследствии ставшей Заслуженным учителем РФ. А в академии курсант Соколов Б.В. все пять лет обучения занимался в Военно-научном обществе под руководством известного ученого в области баллистики и теории управления полетом космических аппаратов профессора Баринова Константина Никитича. Обучение в академии завершилось написанием диплома, посвященного вопросам защитного маневрирования космических аппаратов. Диплом стал частью комплексной работы, подготовленной совместно с учениками доктора технических наук профессора Пономарева В.М. и представленной на конкурс лучших студенческих работ. Эта работа завоевала на общесоюзном конкурсе 1 место.

В воинской части, куда был распределен лейтенант Соколов Б.В., он попал в центр интересных событий, связанных с внедрением первой в СССР интегрированной АСУ разнородными группировками космических аппаратов (КА). Работая в отделении математического и программного обеспечения КА, Соколов Б.В. принимал

непосредственное участие в испытаниях перспективных систем автоматизации. Это дало ему бесценный практический опыт работы со средствами и системами автоматизации процессов управления КА, а также определило профиль будущей исследовательской работы – из «чистого» баллистика, математика Соколова Б.В., существенно расширив профиль своей профессиональной деятельности, стал специалистом по АСУ КА.

Широта научного кругозора Соколова Б.В., проявляющаяся в его способности с единых позиций решать фундаментальные научно-технические проблемы в различных предметных областях, берёт свои истоки в многогранной системно-кибернетической подготовке, полученной им в ходе обучения в адъюнктуре, работе в научных подразделениях и на кафедре, при подготовке кандидатской, а затем докторской диссертаций в рамках научной школы «Системного анализа и космической кибернетики», возглавляемой основателями этой научной школы докторами технических наук профессорами Резниковым Борисом Абрамовичем и Калининым Владимиром Николаевичем. Здесь в методологию научных исследований, проводимых Соколовым Б.В., как на теоретическом, так и на прикладном уровнях, прочно вошли основы системного подхода к решению сложных задач автоматизации управления.

Владение этим подходом и впоследствии, уже при работе в СПИИРАН, позволило Борису Владимировичу под руководством и в сотрудничестве с директором СПИИРАН членом-корреспондентом РАН Юсуповым Рафаэлем Мидхатовичем организовывать и успешно выполнять междисциплинарные исследования, объединяющие результаты ученых и специалистов, работающих в различных предметных областях.

В настоящее время профессор Соколов Б.В. является известным ученым, автором более 800 научных работ, 5 монографий, 5 учебников, 20 изобретений, основателем нового научного направления в области автоматизации процессов проактивного управления сложными техническими объектами (СТО), связанного с комплексным описанием и междисциплинарным исследованием процессов адаптивного многокритериального структурно-функционального синтеза технологий и программ управления развитием СТО в критических приложениях [1 – 25].

Соколов Б.В. выдающийся ученый в области информатики и теории управления, основатель и руководитель успешно развивающейся им научной школы по исследованию проблем проактивного управления структурной динамикой сложных объектов,

в которой получен целый ряд фундаментальных и прикладных результатов, в том числе:

- разработаны научные основы теории проактивного управления структурной динамикой сложных объектов;
- разработан кибернетический подход к многокритериальному оцениванию, анализу и управлению качеством моделей и полимодельных комплексов, описывающих сложные объекты;
- разработаны научно-методологические, методические и технологические основы создания и использования распределенных систем поддержки принятия решений при управлении сложными объектами;
- созданы и внедрены опытные образцы программного обеспечения решения задач календарного планирования и составления расписаний на предприятиях и в организациях ракетно-космической отрасли, в судостроении, в транспортно-логистических системах, в организациях и войсковых частях МО РФ.

Новизна и перспективность исследований, проводимых Соколовым Б.В., эффективность получаемых результатов, послужили основанием для открытия в СПИИРАН новой лаборатории, созданной по его инициативе в 2006 г. Наименование вновь созданного подразделения – Лаборатория информационных технологий в системном анализе и моделировании. Такое название выбрано в соответствии с профилем деятельности института и новым направлением проводимых разработок – системным (комплексным) моделированием в различных предметных областях, а также созданием соответствующих информационных технологий для автоматизации комплексного моделирования. В результате исследований, выполненных лабораторией профессора Соколова Б.В. под руководством и при непосредственном участии директора СПИИРАН члена-корреспондента РАН Юсупова Р.М., сформировано новое направление междисциплинарных исследований – основы квалиметрии моделей и полимодельных комплексов, а также разработаны прикладные программные решения для реализации междисциплинарных проектов. Основные теоретические результаты данного направления нашли отражение в монографии [10].

Еще одним новым направлением исследований, проведенных профессором Соколовым под руководством члена-корреспондента РАН Юсупова Р.М., является развитие неокибернетики как науки, обобщающей результаты классической кибернетики, информатики и системологии и позволяющей с общих позиций перейти к описанию процессов развития не только технических объектов, но социально-

экономических систем как целенаправленных управляемых процессов [11].

Свидетельством фундаментальности и общности полученных профессором Соколовым Б.В. результатов является успешное применение положений разработанной им теории управления структурной динамикой сложных объектов для решения задач управления в транспортно-логистических системах. В отечественной практике это привело к созданию технологии управления грузоперевозками на воздушном транспорте. За решение данной задачи Соколов Б.В. в 2013 в составе авторского коллектива был удостоен звания Лауреата премии Правительства РФ в области науки и техники. Фундаментальные результаты по данному направлению получили и широкое международное признание, опубликованы более чем в 20 статьях в высокорейтинговых международных изданиях и в коллективной монографии, вышедшей под редакцией Соколова Б.В. [20].

В 2021 г. статья [26] была отмечена знаком: «Best Paper in the 2021 IISE Transactions Focus Issue on Design and Manufacturing». Соколов Б.В. входит в список 10 выдающихся учёных РФ международного научного портала Research.com в направлении Engineering and Technology: <https://research.com/u/boris-sokolov>.

Неиссякаемая творческая энергия профессора Соколова Б.В. находит свое воплощение в разработках, выполненных за последние 5 лет и выполняемых в настоящее время. За последние годы им разработаны принципиально новые и превосходящие зарубежные аналоги методы и технологии децентрализованного управления группами беспилотных летательных аппаратов, методы обеспечения функциональной совместимости и интеграции перспективных автоматизированных систем управления различного назначения. В 2023 г. Борис Владимирович второй раз стал Лауреатом Премии Правительства РФ в области науки и техники. Фундаментальные и прикладные результаты по развитию теории проактивного интеллектуального управления структурной динамикой сложных объектов нашли отражение в подготовленной к печати в издании Российской Академии наук монографии «Методология и технологии автоматизации и интеллектуализации процессов проактивного управления сложными объектами» (в соавторстве с Юсуповым Р.М. и сотрудниками возглавляемой Соколовым Б.В. лаборатории).

Говоря подробнее о прикладных результатах, полученных профессором Соколовым Б.В., необходимо отметить, что, начиная с 1978 г., он принимал непосредственное участие в выполнении более

120 научно-исследовательских и опытно-конструкторских работ. Более чем в 40 работах он являлся научным руководителем. При их выполнении Соколовым Б.В. получены результаты, обеспечивающие лидерство российских разработок при решении актуальных научно-технических и социально значимых задач, в том числе: для сферы производства и логистики создана методология структурно-функционального синтеза интеллектуальных информационных технологий и автоматизированных систем управления; для авиакосмической отрасли разработана прикладная теория проактивного мониторинга и управления структурной динамикой систем управления космическими аппаратами и робототехническими комплексами; для решения социально-экономических и агробиотехнических задач созданы теоретические основы комплексного автоматизированного моделирования природных и природно-технических объектов.

Результаты исследований Соколова Б.В. получили широкую практическую реализацию в научных учреждениях, в высокотехнологичных производствах государственного сектора и отдельных компаний (Фонд перспективных исследований, Федеральный исследовательский центр «Информатика и управление» Российской академии наук, Центральный научно-исследовательский институт машиностроения, Конструкторское бюро «Арсенал» имени М.В. Фрунзе, Научно-исследовательский институт космических систем имени А.А. Максимова, и другие). Использование результатов Соколова Б.В. позволяет находить оптимальные решения по построению автоматизированных систем управления, создаваемых для различных отраслей, и существенно повысить эффективность их функционирования на различных этапах жизненного цикла.

Значительные результаты, полученные Соколовым Б.В. при разработке методологии автоматизации и интеллектуализации процессов проактивного управления сложными объектами, оказали существенное влияние на развитие прикладных информационных технологий в Санкт-Петербурге и стране. Наибольшее число практических реализаций получено в отечественной ракетно-космической отрасли. В период с 1990 и по настоящее время под его руководством и при непосредственном участии проводились широкомасштабные фундаментальные и прикладные исследования, выполняемые в интересах МО РФ, и, прежде всего, Военно-космических сил. В частности, профессором Соколовым Б.В. и его учениками был разработан и внедрен в промышленных и военных организациях РФ ряд комбинированных методов, алгоритмов и методик комплексного автоматизированного планирования работы

космических средств и управления их структурной динамикой, который позволил сократить затраты ресурсов и повысить эффективность применения таких космических систем как «ГЛОНАСС», «Глобус», «Строй», «Молния».

Фундаментальные результаты Соколова Б.В. по методологии комплексного моделирования сложных объектов реализованы в системе оперативного прогнозирования речных наводнений, которая впервые в отечественной практике обеспечивает полную автоматизацию цикла сбора данных, моделирования и вывода результатов. Применение системы, разработанной совместно с коллегами из Института водных проблем РАН и кафедры гидрологии суши МГУ им. М.В. Ломоносова в рамках проекта Российского научного фонда 17-11-01254, позволило на 30% повысить оперативность и качество решений по реагированию на чрезвычайные ситуации. В ходе исследований по Программе Союзного государства Соколовым Б.В. осуществлены разработка и внедрение технологий управления применением перспективных многоспутниковых систем России и Беларуси. Результаты испытаний продемонстрировали возможности повышения эффективности спутниковых группировок при применении разработанных технологий не менее чем на 20%.

С 2006 по 2017 гг. Соколов Б.В. являлся заместителем директора СПИИРАН по научной работе, выполняя широкий круг обязанностей по организации и выполнению институтом планов фундаментальных и прикладных исследований, организации подготовки кадров высшей квалификации – кандидатов и докторов наук, организации и проведению отраслевых, всероссийских и международных конференций, взаимодействию с внешними организациями и многие другие. На этом посту ярко проявились его способности к системному обобщению различных направлений деятельности лабораторий СПИИРАН и определению направлений интеграции проводимых в институте разработок. Под непосредственным руководством Соколова Б.В. в СПИИРАН открыт отдел аспирантуры, что позволило значительно расширить возможности института по набору молодых исследователей, повышению качества их обучения и подготовки диссертаций.

Системообразующая деятельность профессора Соколова Б.В. распространяется и за пределы СПИИРАН. При его активнейшем участии было создано Национальное общество имитационного моделирования, президентом которого он является с 2024 г. Первоочередная задача общества – сформировать связи между специалистами в области моделирования в России, определить круг

организаций, институтов и промышленных предприятий, использующих моделирование как средство исследования и проектирования, способствовать созданию горизонтальных связей для объединения усилий при выполнении междисциплинарных проектов.

Профессор Соколов Б.В. ведет активную педагогическую деятельность. Опыт его преподавательской деятельности включает работу преподавателем и начальником кафедры в Военно-космической академии им. А.Ф. Можайского (1982-1998 гг.), профессором кафедры «Инженерного обеспечения городского хозяйства» Санкт-Петербургского Государственного технического университета, профессором кафедры «Компьютерных технологий и программной инженерии» Санкт-Петербургского Государственного университета аэрокосмического приборостроения (с 1999 г.), профессором Департамента логистики и управления цепями поставок Национального исследовательского университета Высшей школы экономики в г. Санкт-Петербурге (с 2016 г.).

Для профессора Соколова Б.В. чтение лекций, проведение занятий со студентами и аспирантами – важнейший вид деятельности. Воспитанный выдающимися учеными и педагогами в ВИКИ им. А.Ф. Можайского, он руководствуется их подходом и высокоответственным отношением к общению с учениками. Передача накопленного опыта и знаний следующим поколениям инженеров и исследователей всегда проходит в уважительном тоне. Профессор Соколов Б.В. не жалеет времени и усилий. Научные дискуссии традиционно сопровождаются примечательными историческими справками и начертанием витиеватых, но безукоризненно точных математических формул.

Учебники, учебные пособия, написанные Соколовым Б.В. и с его участием, прочно вошли в фундамент системно-кибернетического образования инженеров и исследователей в ВИКА им. Можайского, Военно-космических силах, Министерстве обороны РФ, учреждениях РАН, и многих других организациях.

Существенным вкладом Соколова Б.В. в развитие науки является его деятельность по подготовке высококвалифицированных кадров и руководство научной школой исследования проблем проактивного управления структурной динамикой сложных объектов. Им подготовлено 5 докторов технических наук и 15 кандидатов наук.

Важно отметить наличие у проф. Соколова Б.В. принципиальной позиции – никаких уступок слабым научным результатам. Такой подход должен был бы являться причиной множества межличностных конфликтных ситуаций, однако глубокое

человеколюбие, бесконечное терпение и чувство такта всегда позволяют юбиляру посмотреть на ситуацию как на возможность развить новую идею или пробудить в собеседнике интерес к по-прежнему актуальным фундаментальным работам.

Профессор Соколов Б.В. ведёт большую научно-организационную работу: является членом учёных советов СПб ФИЦ РАН и СПИИРАН, двух диссертационных советов (в том числе и в Военно-космической академии им. А.Ф. Можайского), членом Федерации космонавтики РФ, действительным членом международной Академии навигации и управления движением, членом Ученого совета Библиотеки РАН, членом Научного совета по информатизации Санкт-Петербурга. Особым признанием заслуг научной школы профессора Соколова Б.В. является его назначение на пост председателя секции «Кибернетики им. академика А.И. Берга» при Доме учёных им. М. Горького РАН.

Соколов Б.В. неоднократно входил в состав программных комитетов всероссийских и международных конференций, в том числе является членом организационного комитета Международной научной школы «Моделирование и анализ безопасности и риска в сложных системах», членом программного комитета конференции «Кибернетика и высокие технологии XXI века», председателем программного комитета конференции «Имитационное моделирование. Теория и практика», является членом ряда редакционных советов и редколлегий российских и зарубежных журналов в области информатики и теории управления (в том числе «Известия вузов. Приборостроение», «Информационные технологии», «Информатизация и связь», «Надежность», «Вопросы радиоэлектроники»).

Сотрудники СПб ФИЦ РАН, коллеги из многих организаций, его ученики и последователи, редакционная коллегия журнала «Информатика и автоматизация» (Труды СПИИРАН) от души поздравляют Соколова Бориса Владимировича с юбилеем и желают ему крепкого здоровья и дальнейших творческих успехов!

Основные публикации Соколова Б.В.

1. Соколов Б.В., Калинин В. Н. Динамическая модель и алгоритм оптимального планирования комплекса работ с запретами на прерывание. Автоматика и телемеханика. 1985. № 5. С. 106–114.
2. Соколов Б.В., Калинин В.Н. Динамическая модель процесса переналадки приборов активного подвижного объекта. Дифференциальные уравнения. 1987. Т. 23. № 9. С. 1626–1629.
3. Соколов Б.В., Калинин В.Н., Оптимальное планирование процесса взаимодействия активных подвижных объектов. Дифференциальные уравнения. 1985. Т. 21. № 5. С. 752–757.
4. Соколов Б.В. Комплексное моделирование операций и управление структурами в АСУ активными подвижными объектами. М.: МО, 1992. 232 с.
5. Соколов Б.В., Юсупов Р.М. Концептуальные основы оценивания и анализа качества моделей и полимодельных комплексов. Теория и системы управления. 2004. № 6. С. 5–16.
6. Соколов Б.В., Калинин В.Н. Многомодельный подход к описанию процессов управления космическими средствами. Теория и системы управления. 1995. № 1. С. 149–156.
7. Соколов Б.В., Юсупов Р.М. Комплексное моделирование рисков при выработке управленческих решений в сложных организационно-технических системах. Проблемы информатики и управления. 2006. № 1, № 2. С. 39–59.
8. Охтилев М.Ю., Соколов Б.В., Юсупов Р.М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. М.: Наука, 2006. 410 с.
9. Павлов А.Н., Соколов Б.В., Москвин Б.В., Верзилин Д.Н. Военная системотехника и системный анализ: учебник. СПб.: ВКА имени А.Ф. Можайского, 2010. 251 с.
10. Микони С.В., Соколов Б.В., Юсупов Р.М. Квалиметрия моделей и полимодельных комплексов. М.: РАН, 2019. 314 с.
11. Юсупов Р.М., Соколов Б.В. Роль и место неокибернетики в современной структуре системы знаний. Мехатроника, автоматизация, управление. 2009. № 6(99).
12. Юсупов Р.М., Соколов Б.В., Охтилев М.Ю. Теоретические и технологические основы концепции проактивного мониторинга и управления сложными объектами. Известия Южного Федерального университета. Технические науки. 2015. № 1(162). С. 162–174.
13. Ivanov D., Sokolov B. Adaptive Supply Chain Management. London: Springer. 2010. 269 p.
14. Ivanov D., Sokolov B. Control and system-theoretic identification of the supply chain dynamics domain for planning, analysis, and adaptation of performance under uncertainty. European Journal of Operational Research. 2013. vol. 224(2). pp. 313–323.

15. Ivanov D., Sokolov B., Dolgui A. Optimal Control Algorithms and Their Analysis for Short-Term Scheduling in Manufacturing Systems. *Algorithms*. 2018. vol. 11(5). DOI: 10.3390/a11050057.
16. Ivanov D., Sokolov B. Dynamic supply chain scheduling. *Journal of Scheduling*. 2012. vol. 15(2). pp. 201–216.
17. Dolgui A., Dmitry Ivanov D., Sokolov B., Suresh P. Sethi. Scheduling in production, supply chain and Industry 4.0 systems by optimal control: fundamentals, state-of-the-art and applications. *International Journal of Production Research*. 2018. vol. 56(1-2). pp. 414–430.
18. Ivanov D., Sokolov B. Dynamic coordinated scheduling in the supply chain under a process modernization. *International Journal of Production Research*. 2013. vol. 51(9). pp. 2680–2697. DOI: 10.1080/00207543.2012.737950.
19. Zelentsov V., Sokolov B., Merkuryev Y., Yusupov R. Multiple models of information fusion processes: Quality definition and estimation. *Journal of Computational Science*. 2014. vol. 5(3). pp. 380–386.
20. Sokolov B., Ivanov D., Dolgui A. Scheduling in Industry 4.0 and Cloud Manufacturing. *International Series in Operations Research & Management Science*. 2020. vol. 289. 273 p.
21. Калинин В.Н., Кулаков А.Ю., Павлов А.Н., Потрясаев С.А., Соколов Б.В. Методы и алгоритмы синтеза технологий и программ управления реконфигурацией бортовых систем маломассоразмерных космических аппаратов. *Информатика и автоматизация*. 2021. Т. 20. № 2. С. 236–269.
22. Охтилев М.Ю., Охтилев П.А., Соколов Б.В., Юсупов Р.М. Методологические и методические основы проактивного управления жизненным циклом сложных технических. *Известия ВУЗов. Приборостроение*. 2022. № 11. С. 781–788.
23. Захаров В.В., Баранов А.Ю., Соколов Б.В., Юсупов Р.М. Модели и алгоритмы централизованного и децентрализованного планирования применения группировки подвижных объектов на основе теории дифференциальных игр. *Морские интеллектуальные технологии*. 2023. № 4. Ч. 1. С. 171–178.
24. Sokolov B., Ushakov V., Zakharov V. Optimal planning and scheduling of information processes during interaction among mobile objects. *International Journal of Production Research*. 2024. pp. 1–20.
25. Fu M., Li S., Jin Y., Zhang W.-A., Sychou U., Skobtsov V., Sobolevskii V., Sokolov B. Fusion or not: Learning visual relocalization with matrix Fisher distribution. *Neurocomputing*. 2025. vol. 618. DOI: 10.1016/j.neucom.2024.129033.
26. Ivanov D., Sokolov B., Chen W., Dolgui A., Werner F., Potryasaev S. A control approach to scheduling flexibly configurable jobs with dynamic structural-logical constraints. *IISE Transactions*. 2021. vol. 53(1). pp. 21–38.

П.В. ПЛОТНИКОВ, Г.И. ТАМБОВЦЕВ, А.Г. ВЛАДЫКО

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ МНОГОКРИТЕРИАЛЬНОЙ БАЛАНСИРОВКИ ПАРАМЕТРОВ V2X-СИСТЕМ

Плотников П.В., Тамбовцев Г.И., Владыко А.Г. Математическая модель многокритериальной балансировки параметров V2X-систем.

Аннотация. Развитие интеллектуальных транспортных систем и внедрение архитектуры Vehicle-to-Everything (V2X) предъявляют высокие требования к характеристикам сетевого взаимодействия, таким как минимальная задержка, высокая надёжность и энергоэффективность. При этом снижение одного из параметров влечет за собой увеличение другого, что делает задачу их сбалансированной настройки актуальной и практически значимой. Особенно важно учитывать не только общую задержку (задержка сети связи и вычислительная задержка) и энергопотребление, но и ожидаемое время прибытия мобильного вычислительного узла на базе транспортного средства – интегральный показатель качества обслуживания в динамически меняющейся среде. В настоящей работе предлагается математическая модель многопараметрической оптимизации параметров функционирования V2X-системы, учитывающая три взаимосвязанных показателя: общую задержку, энергопотребление и ожидаемое время прибытия. Модель формализует структуру транспортной системы в виде ориентированного графа, с заданными маршрутами движения, размещением стационарных и мобильных вычислительных узлов транспортной инфраструктуры, а также параметрами обмена видеоданными между ними и терминальными устройствами. Модель представлена в виде задачи оптимизации и позволяет настраивать систему в соответствии с внешними условиями и прикладными целями. В качестве исследовательского инструмента использованы методы имитационного моделирования с реалистичными сценариями движения транспортных средств и переменной нагрузкой сети связи. Результаты проведённых численных экспериментов позволяют показать, что использование предложенной модели позволит достичь более сбалансированных режимов работы системы, снижая общие задержки и энергозатраты без ухудшения параметров времени прибытия. По сравнению с традиционными подходами, основанными на однокритериальной или двухкритериальной оптимизации, предложенный метод обеспечивает большую адаптивность и устойчивость V2X-систем к изменяющимся условиям функционирования. Сформулированные выводы могут быть полезны исследователям при проектировании и внедрении энергоэффективных и надёжных распределённых архитектур в современных транспортных системах.

Ключевые слова: Vehicle-to-Everything, V2X, многопараметрическая оптимизация, математическое моделирование, интеллектуальные транспортные системы, граничные вычисления, туманные вычисления.

1. Введение. Стремительное развитие беспроводных сенсорных сетей и технологий Интернета вещей (Internet of Things, IoT) стало катализатором появления множества промышленных приложений, требующих обработки и хранения большого объема данных. Все они предъявляют жесткие требования к вычислительной мощности устройств и их энергоэффективности. Однако обычные стационарные устройства конечных пользователей часто не обладают достаточным

потенциалом, необходимым для удовлетворения требований к качеству обслуживания (Quality of Service, QoS) таких приложений [1, 2]. В отличие от предыдущих исследований авторов, посвящённых анализу телеметрического трафика [3, 4], в настоящей работе предлагается математическая модель многопараметрической балансировки параметров системы для анализа более ресурсоёмкого сценария – передачи видеопотока. Такой выбор позволяет протестировать модель в условиях повышенной нагрузки сети связи и чувствительности к потерям, а также сопоставить её работу в телеметрических и мультимедийных сценариях. В качестве балансируемых параметров используются общая задержка (задержка сети связи и вычислительная задержка); энергопотребление вычислительных узлов; ожидаемое время прибытия мобильного вычислительного узла на базе транспортного средства.

В современных системах связи для транспортных систем [5, 6] облачные вычисления и высокоскоростные широкополосные сети связи позволяют переложить большинство вычислительных задач на удаленные облачные серверы. Хотя такой подход становится все более распространенным с каждым новым поколением коммуникационных технологий, отправка данных в удаленное облако все еще может приводить к значительным сетевым задержкам. При таком подходе ресурсоемкие задачи передаются на удаленные высокопроизводительные облачные серверы Vehicle Cloud Computing (VCC), использующие централизованную облачную инфраструктуру для обеспечения транспортных средств (ТС) масштабируемыми возможностями обработки, хранения и обслуживания, а также для снижения энергопотребления. Несмотря на свои преимущества, VCC часто подвергается серьезной критике из-за высокой сетевой задержки, что является серьезным ограничением эффективности для приложений, критичных к задержкам, а также зачастую имеют высокие энергозатраты.

Для смягчения этих ограничений для приложений, требующих оперативного реагирования в реальном времени, была разработана парадигма граничных вычислений (Edge Computing, EC), которая оказалась перспективным решением, в том числе для интеллектуальных транспортных систем (ИТС) [7]. Интегрируя граничные вычисления в транспортные системы, поставщики услуг могут рассчитывать на взаимодействие с ультрамалой задержкой, размещая вычислительные ресурсы ближе к устройствам конечных пользователей на границе сети связи.

За последнее время был предложен ряд подходов к разгрузке вычислений для ТС. Некоторые из них предполагают использование одного сервера, а другие – нескольких серверов. Однако большинство существующих решений по разгрузке задач позволяют ТС передавать свои задачи на один и тот же связанный граничный сервер, что увеличивает сетевую задержку и ограничивает повышение производительности. Кроме того, некоторые из рассматриваемых устройств могут быть не в состоянии выполнять вычисления в отведенное время, требуя при этом высокий уровень энергозатрат. Для преодоления описанных ограничений используются методы кэширования и оптимизации пакетов, чтобы уменьшить объем передаваемых данных в системе.

Несмотря на все преимущества парадигмы граничных вычислений, возникает проблема ее строгой локальности и ограниченности ресурсов конкретных вычислительных устройств. В этой связи, в качестве альтернативы, менее чувствительной к задержкам, была предложена парадигма туманных вычислений (Fog Computing, FOG) [8]. FOG – это архитектурная модель, при которой обработка данных, хранение и сетевые функции частично переносятся с центрального облака на более близкий к источнику данных уровень – «туман», то есть на промежуточные устройства и узлы, расположенные между облаком и конечными устройствами (датчиками, смартфонами, автомобилями и пр.).

Парадигмы граничных и туманных вычислений имеют ряд преимуществ над облачными вычислениями [9, 10], поэтому их комплексное внедрение позволит увеличить скорость работы ИТС, снизить уровень энергопотребления и повысить уровень управляемости динамической системы, в целом. В то же время, улучшение одного из показателей может привести к ухудшению других, что требует поиска компромиссных решений, соответствующих целям конкретной V2X-системы. В настоящем исследовании предлагается подход к решению задачи оптимизации, учитывающий дополнительный параметр – ожидаемое время прибытия мобильного вычислительного узла (Estimated Time of Arrival, ETA), что обеспечивает более гибкий и адаптивный механизм. Решение задачи поиска уравнения баланса нагрузки на объекты V2X-системы может быть найдено посредством внедрения ряда инфраструктурных решений, детальный обзор которых приведен в [11]. Влияние приведенных подходов на эффективность функционирования V2X-систем подробно рассматривается в ряде работ [12 – 15].

В данной статье предлагается решение задачи оптимизации баланса производительности, энергоэффективности и ресурсозатрат для ИТС при использовании V2X-технологий с элементами периферийных вычислений. Построена математическая модель для имитационного моделирования и приведено её численное решение для V2X-системы в конфигурации с традиционным размещением придорожных вычислительных узлов (RSU), использующей двухканальную схему соединения между бортовыми устройствами (OBU) и RSU.

При моделировании применяется трехуровневая вычислительная архитектура взаимодействия элементов V2X-системы [16]. Данная архитектура расширяет существующие стационарные узлы (RSU), добавляя использование подвижных элементов (mRSU) – мобильных вычислительных узлов, которые могут быть размещены на специализированных ТС, которые, в свою очередь образуют динамическую систему туманных вычислений (динамический туман, Dynamic FOG). Внутри тумана – объекты (OBU) являются границами друг для друга и для mRSU. Они используют граничные вычисления для выполнения задач. Для внешних участников (OBU), не имеющих возможности объединиться с mRSU, но имеющих возможность обратиться к одному из участников динамического тумана, образуется FOG.

На рисунке 1 представлен пример рассматриваемой V2X-системы, где синей областью обозначен динамический туман. Синими пунктирными стрелками показаны соединения между участниками этого динамического тумана. Оранжевой пунктирной стрелкой обозначено прямое/опосредованное соединение с участниками динамического тумана. Так, например, OBU3, имея лишь одно соединение с OBU2, имеет возможность обратиться к участникам динамического тумана.

В рамках исследования проводится количественная оценка эффективности работы модели. В частности, анализируется процент необработанных запросов, генерируемых бортовыми устройствами в процессе движения ТС, а также вычисляется общая задержка передачи и обработки запросов в системе OBU-RSU. Приводится оценка энергетических затрат в системе с учетом нагрузки системы реальными данными. Сравнение полученных результатов осуществляется как для случая использования только стационарных RSU, так и с добавлением мобильных RSU (mRSU), рассматриваемых как элементы динамического тумана. Для этого моделируются как целевые, так и случайные траектории движения mRSU с целью оценки их влияния на общую отказоустойчивость и производительность системы.

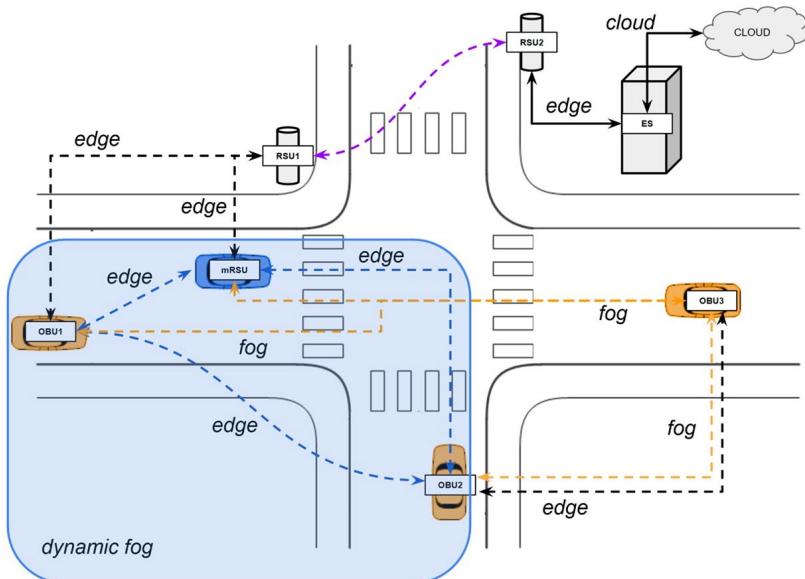


Рис. 1. Пример организации V2X системы

В ряде статей [17–21] уже предпринималась достаточно успешные попытки найти баланс между задержкой при передаче данных и энергозатратами системы, но в каждом отдельном случае накладывались ряд ограничений. В данной работе акцент сделан на поиске уравнения баланса по трем параметрам: общая задержка при передаче и обработке задачи, энергетические затраты и ожидаемое время прибытия ЕТА.

Научная новизна предлагаемого исследования заключается в постановке и численном решении задачи оптимизации балансировки нагрузки V2X-системы с учетом использования периферийных вычислений на базе мобильных вычислительных узлов mRSU, позволяющих уменьшить общую задержку и снизить энергопотребление вычислительных узлов. В частности, учет параметров динамического тумана при решении задач балансировки нагрузки V2X-системы ранее не рассматривался.

Остальная часть статьи построена следующим образом: В разделе 2 представлен обзор существующей литературы в соответствующей предметной области. В разделе 3 сформулировано описание модели системы и применяемого математического аппарата. Представлены основные параметры оптимизируемой системы и получено уравнение баланса между выбранными параметрами.

В разделе 4 представлены и описаны результаты численного моделирования, направленные на подтверждение теоретических выводов и их анализ в различных конфигурациях системы. Наконец, в разделе 5 приводятся заключительные замечания и обсуждение.

2. Обзор связанных исследований и разработок. В этом разделе представлен краткий обзор известных работ по схожей с настоящим исследованием тематике. Выделены основные преимущества и недостатки подходов, разработанных другими авторами.

В работе [17] предложен новый алгоритм балансировки нагрузки, обеспечивающий эффективное перераспределение транспортных средств между RSU с учетом таких параметров, как степень их загрузки, вычислительные ресурсы и скорость передачи данных.

Реализована усовершенствованная стратегия кэширования, позволяющая граничным серверам сохранять результаты выполненных задач, что способствует снижению задержек и энергопотребления. Задача оптимизации формулируется как задача минимизации энергозатрат при соблюдении ограничений по задержке. Ввиду высокой вычислительной сложности данной задачи в условиях крупномасштабных транспортных сетей разработана эквивалентная модель обучения с подкреплением, для которой применён алгоритм глубокого обучения с целью получения оптимальных решений. Отдельное внимание в исследовании уделяется кластерному подходу, позволяющему организовать эффективное взаимодействие компонентов ИТС. При этом рассмотренный подход никак не учитывает загруженность транспортной системы и наличие в ней заторов в реальном времени, то есть балансировка осуществляется с существенной задержкой на основе собранных данных.

Целью исследования в работе [18] является формализация задачи распределения нагрузки в виде двухкритериальной задачи оптимизации и выбор базового метода решения. В рамках предложенного подхода рассматриваются два ключевых критерия оценки вычислительных устройств дорожной инфраструктуры: уровень заряда батареи и остаточный вычислительный ресурс. Последний может быть количественно определён либо через вероятность безотказной работы устройства, либо как величина, обратная интенсивности отказов, при условии, что отказоустойчивость моделируется с использованием экспоненциального закона распределения. На основании этих предпосылок сформулирована модель двухкритериальной оптимизации, учитывающая изменения

топологии телекоммуникационной сети в процессе выполнения пользовательских задач. В соответствии с представленной моделью разработан метод ресурсосбережения в краевом и туманном слоях вычислительной сети, который учитывает динамическую природу сетевой архитектуры, а также относительную важность критериев, определяющих износ и расход ресурсов устройств. При этом несмотря на то, что в работе затрагиваются вопросы топологии сети и энергоэффективности системы, фактор задержки при передаче данных не учитывается.

В работе [19] представлена энергоэффективная архитектура «Vehicular Edge-Cloud Computing», в которой применяется механизм кэширования выполненных задач на уровне граничных серверов. Это позволяет существенно снизить задержки при повторной обработке задач и минимизировать общее энергопотребление при соблюдении заданных ограничений на время отклика. Модель оптимизации, предложенная авторами, демонстрирует высокую эффективность по сравнению с базовыми подходами, однако не рассматривает аспект справедливости распределения нагрузки между вычислительными узлами и не адаптируется к изменяющимся характеристикам устройств в реальном времени.

В работе [20] предложен альтернативный подход, ориентированный на справедливое распределение вычислительной нагрузки между узлами туманной среды. Авторы formalизовали метрики задержки и энергопотребления, а также определили количественную меру справедливости планирования задач. В рамках предложенной двухэтапной схемы «Fair Task Offloading», сначала выбираются туманные узлы на основе метрики справедливости, а затем задачи распределяются между выбранными узлами с учетом минимизации задержек. Данный подход обеспечивает более сбалансированное распределение нагрузки, но при этом не учитывает деградацию вычислительных ресурсов устройств, остаточную энергию, надежность оборудования, а также динамику сети.

В исследовании [21] рассматривается проблема справедливой разгрузки в сетях IoT с поддержкой тумана, особенно для туманных узлов (Fog Nodes, FN), работающих от батарей. Авторы предлагают алгоритм FEMTO, который основан на метрике справедливости и учитывает три ключевых параметра: разгрузку задач, энергопотребление и приоритет узлов. Аналитически выведены оптимальные значения целевых FN, мощности передачи и размера подзадач. Проведено обширное моделирование для гетерогенной сети IoT с поддержкой тумана. Численные результаты показывают, что

предложенный алгоритм FEMTO эффективно определяет FN-целесообразность и минимальное потребление энергии для сервисов разгрузки задач.

Таким образом, существующие методы либо ориентированы на минимизацию энергопотребления [19–21], либо на достижение справедливого распределения нагрузки [17, 18], однако комплексная модель, учитывающая остаточные ресурсы, надёжность оборудования и динамическую топологию сети, изучена значительно меньше. Кроме того, большинство существующих моделей оптимизации предполагают статичную топологию вычислительной сети и не учитывают изменение положения и способность к выполнению расчетов вычислительных узлов.

В условиях постоянно изменяющейся сетевой инфраструктуры, характерной для V2X-среды, требуется формализация процессов взаимодействия между компонентами системы с учётом временных, энергетических и пространственных ограничений. Это особенно актуально для гибридных архитектур, включающих как стационарные (RSU), так и мобильные (mRSU) вычислительные узлы, обладающие различным уровнем вычислительных ресурсов и разной степенью доступности.

Для комплексного анализа поведения таких систем и выработки обоснованных стратегий управления была разработана математическая модель, включающая в себя взаимосвязанные подсистемы, каждая из которых отражает определённый аспект функционирования V2X-инфраструктуры.

3. Математическая модель V2X-системы. Описание математической модели представлено в виде совокупности взаимосвязанных компонент, каждая из которых отвечает за определённый аспект функционирования распределённой вычислительной сети транспортной инфраструктуры.

Основу комплексной модели составляют следующие компоненты:

1. Системная модель, описывающая структуру вычислительной сети, характеристики вычислительных узлов, распределение нагрузки и динамику перемещения мобильных компонентов.

2. Коммуникационная модель, формализующая процессы передачи и получения информации, задержки, потери пакетов и загрузку каналов связи.

3. Вычислительная модель – модель обработки данных, включающая параметры энергопотребления, тактовой частоты, объёмов вычислений и времени отклика.

4. Модель ЕТА – оценочная модель, реализующая ожидаемое время прибытия мобильного вычислительного узла (ETA).

Интеграция этих компонентов позволяет сформировать уравнение баланса, необходимое для количественного анализа производительности системы и адаптивного управления распределением задач в условиях ограниченных ресурсов. Однако, следует заметить, что модель ориентирована на сценарии средней плотности городского трафика. Экстремальные условия, такие как крупные аварии, массовые эвакуации или резкие изменения погодных условий, не моделировались и могут повлиять на точность прогноза ETA. Масштабируемость модели проверялась на ограниченном числе RSU и OBU; при увеличении числа параметров на порядок могут потребоваться иные алгоритмы балансировки и перераспределения нагрузки. В модели задержка в очереди описывается системой M/M/1 без установления приоритетов различных типов трафика, что упрощает оценку, но не учитывает возможное влияние механизмов приоритетного обслуживания (например, для экстренных сообщений). В рамках расчётов рассматривается ограниченное число типов сервисов – видеопоток и сообщения формата САМ, которые характерны для задач мониторинга и ситуационного оповещения в V2X-системах. Передача других типов данных (например, голосовых сообщений, телеметрии высокой частоты или мультимедийных потоков с приоритетом) не моделировалась, что может влиять на распределение ресурсов и параметры общей задержки в реальных смешанных сценариях.

3.1. Системная модель и ее элементы. Для получения уравнения баланса, необходимого для анализа параметров, требуется определить модель исследуемой системы, включая её ключевые элементы и характеристики.

Рассматриваемая V2X-система ориентирована на структуру городской дорожной сети, которая описана в виде ориентированного графа $G = (V, R)$, где V – множество вершин, соответствующих перекрёсткам, а $R \subseteq V \times V$ – множество рёбер, представляющих собой прямолинейные участки дорог. Каждый участок дороги может поддерживать одностороннее или двустороннее движение, однако в рамках модели предполагается однополосное движение с учётом направленности рёбер графа.

Каждому ребру $r_{ij} = (v_i, v_j) \in R$ сопоставляется вес w_{ij} , представляющий длину участка дороги или среднее время проезда с учётом трафика. Возможность двустороннего движения моделируется наличием парных рёбер (v_i, v_j) и (v_j, v_i) с возможными различиями в весах.

Пусть $A = \{a_1, a_2, \dots, a_N\}$ – множество транспортных средств, каждое из которых оборудовано бортовым вычислительным модулем (OBU), обеспечивающим телекоммуникационные и вычислительные функции. Для каждого $a_k \in A$ задаётся пара $(s_k, d_k) \in V \times V$, обозначающая стартовую и конечную вершины маршрута. На начальном этапе OBU определяет индивидуальный маршрут:

$$RT_k = \{v_{k1}, v_{k2}, \dots, v_{kL}\} \subset V, v_{k1} = s_k, v_{kL} = d_k,$$

а маршрут RT_k представляет собой путь, минимизирующий суммарный вес:

$$RT_k = \arg \min_{P=\{v_1, v_2, \dots, v_m\} \in \Omega(s_k, d_k)} \sum_{l=1}^{m-1} w_{v_l v_{l+1}}^{(k)},$$

где $\Omega(s_k, d_k)$ множество допустимых путей от $v_1 = s_k$ до $v_m = d_k$ в графе G .

Таким образом, перед началом движения ТС каждое OBU самостоятельно формирует маршрут, основываясь на принципе кратчайшего пути от начальной точки до заданного пункта назначения. При этом маршрут фиксируется заранее и не изменяется в процессе движения, что позволяет формализовать поведение транспортных средств как детерминированное во временном интервале моделирования. Движение ТС в городской среде описывается совокупностью маршрутов на графе G , а OBU – агенты, принимающие локальные решения на основе глобальной информации о структуре графа. Данная модель служит основой для дальнейшего построения балансовых уравнений и анализа распределения нагрузки и взаимодействия между элементами ИТС, включая краевые и туманные вычислительные узлы.

Скорости движения ТС представляют собой поток независимых, одинаково распределенных случайных величин. Эти скорости распределены по усеченному нормальному закону распределения [22].

Пусть скорость u каждого OBU на участке дороги (внутри области действия одного RSU) лежит в диапазоне от наперед заданных минимальной до максимальной скорости, то есть

$$u_{\min} \leq u \leq u_{\max}.$$

Модель системы рассматривается в условиях дискретного времени $t = 0, 1, 2, \dots$ В каждый момент времени транспортное средство a_k занимает некоторое ребро $r_{ij} \in R$ или вершину $v_j \in V$ графа, переходя между ними с вероятностями, зависящими от текущей загрузки и характеристик дороги. Пусть $p_{ij}^{(k)}(t)$ – вероятность того, что в момент времени t автомобиль a_k перемещается из v_i в v_j .

Обозначим через $\lambda_j(t)$ интенсивность потока транспортных средств, прибывающих в узел v_j в момент времени t . Тогда уравнение баланса потока для вершины v_j записывается следующим образом:

$$\lambda_j(t+1) = \sum_{v_i \in pr(v_j)} \lambda_i(t) p_{ij}(t),$$

где $pr(v_j)$ – множество всех вершин, из которых возможен переход в v_j . Если ввести числовую характеристику $\mu_j(t)$, как интенсивность обработки задач в вычислительном узле, расположенном в v_j , то можно задать функцию $\rho_j(t) = \lambda_j(t) / \mu_j(t)$ – коэффициент загрузки узла. Комплексный подход к минимизации $\rho_j(t)$ позволит оптимизировать задержку, энергопотребление и надежность работы системы.

Рассмотрим набор из S стационарных RSU, размещенных на карте, ассоциированных с определённой вершиной или ребром графа. RSU может взаимодействовать с OBU для разгрузки задач, передачи и сбора телеметрических данных. Каждое RSU $s \in S$ оснащено ограниченным кэшем размера Z_s , который используется для

кэширования обрабатываемых данных. Считаем, что каждое RSU имеет зону покрытия в виде круга диаметром L_s .

3.2. Коммуникационная модель с учетом временных задержек. В качестве запрашиваемого контента в модели рассматриваются видеопоток, передаваемый посредством протокола передачи данных в реальном времени (Real-time Transport Protocol, RTP) [23].

Для оценки качества предоставления видеосервиса необходимо определить пороговое значение потерь пакетов, при превышении которого воспроизведение видео становится невозможным или его качество оказывается неприемлемым для восприятия. Важным этапом в рамках такого анализа является определение структуры видеопотока, а именно: типа и последовательности кадров (I-, P-, B-кадров), формирующих конкретный видеопоток.

Представленный детальный разбор структуры сжатого видеопотока необходим для того, чтобы количественно определить порог «потери» в условиях моделирования. Понимание зависимости качества от потерь пакетов позволяет корректно включить видеотрафик в расчёт функции баланса и сопоставить результаты с телеметрическим сценарием.

Видеопоток организован в группы кадров (group of pictures, GOP) [24], обычно следующих по схеме: «*IBBPBBP...I*». Расстояние между I-кадрами и количеством P/B-кадров внутри GOP определяются требованиями к сжатию, устойчивости к потерям и возможностям декодирования в реальном времени. GOP с большим интервалом между I-кадрами позволяет значительно уменьшить общий битрейт, но делает видеопоток более уязвимым к потерям.

I-кадры, или внутрикадровые изображения, кодируются независимо от других кадров, подобно одиночному изображению. Они используют только пространственное предсказание, не опираясь на данные предыдущих или последующих кадров. Являясь точками доступа в кодированном потоке (group of pictures, GOP), I-кадры играют ключевую роль при восстановлении видеоданных после потерь пакетов.

P-кадры (Predicted-frames) используют межкадровое предсказание: они кодируют только разницу относительно предыдущего I- или P-кадра с помощью векторных предсказаний движения (motion vectors) и остаточных данных.

B-кадры (Bidirectional-frames) применяют двунаправленное предсказание: они кодируют разницу сразу от предыдущего и последующего опорных кадров (I или P).

Потеря I-кадра разрушает все зависимые от него P- и B-кадры до следующего I-кадра, делая даже короткие фрагменты видео нечитаемыми. Потери P-кадров приводят к искажениям в зависимых P/B-кадрах. Потеря B-кадра менее критична, поскольку он не участвует в предсказании других кадров.

С целью анализа видеопотока для дальнейшего моделирования выбран программный инструмент FFmpeg, позволяющий извлечь и проанализировать состав видеокадров, их тип и периодичность. Полной потерей видео считается, если утрачено более 5% пакетов или, если пропущены все или большинство I-кадров, или если битрейт видео в несколько раз превышает скорость скачивания. Для моделирования передачи видеопотока, предварительно зафиксированный сетевой трафик, использования RTP был передан в собственную контролируемую среду [25]. Полученные данные в виде последовательности сетевых пакетов записаны и сохранены для последующей обработки.

Будем предполагать, что каждое RSU или mRSU может обслуживать OBU последовательно. Каждое устройство дорожной инфраструктуры может одновременно обрабатывать до 2 запросов от OBU, так как в модели предполагается использование протокола IEEE 802.11bd, имеющего важное преимущество в виде технологии соединения каналов. Это позволит увеличить скорость передачи данных и снизить задержки и величину потери пакетов [26].

Если OBU покидает область покрытия RSU, то взаимодействие прекращается. OBU может подключиться к следующему RSU, в случае если оно свободно. Считается, что RSU по окончании работы с каким-либо OBU может начать обслуживание следующего мгновенно. Блоки данных, которые не были полностью обработаны при информационном взаимодействии с предыдущим OBU, теряются.

Пусть каждое OBU и каждое RSU формируют информацию в виде вектора M некоррелированных элементов данных,

$$M = \{1, 2, \dots, m\}.$$

Предположим, что все элементы данных имеют одинаковый размер C байтов. Каждое RSU обслуживает подключенное OBU со скоростью α_s байт в секунду.

Описанная коммуникационная модель позволяет сформулировать описание механизма разгрузки задач в туманных и граничных узлах сети. Общая задержка представляет собой сумму нескольких компонент, отражающих как локальные, так и удалённые

вычислительные процессы. Как было представлено выше, задача $M = \{1, 2, \dots, m\}$ разделена на набор подзадач, каждая из которых, либо обрабатывается локально на границе (Edge Node, EN), либо выгружена на туманный узел FN для удалённой обработки.

Общая задержка выполнения i -й подзадачи, обозначаемая как $T_{i,q}$, где $q = e/f$ для EN и FN соответственно, складывается из следующих компонент:

Задержка передачи данных: $T_{i,q}^{td} = \frac{l_{i,q}}{u_{i,q}^{uplink}}$, где $l_{i,q}$ – объём данных подзадачи (в битах), $u_{i,q}^{uplink}$ – пропускная способность канала связи между OBU и выбранным EN или FN для загрузки.

Пропускная способность канала B_i , на котором осуществляется передача данных, определяется через теорему Шеннона для канала с шумом. Используя передаточную мощность терминала p_i , пропускная способность канала вычисляется следующим образом:

$$B_i = u_{i,q}^{uplink} = \log_2 \left(1 + \frac{p_i \gamma_i \beta_i}{I_i + W N_0} \right),$$

где γ_i – фактор потерь сигнала для данного беспроводного канала, β_i – фактор затемнения, отражающий изменения в интенсивности сигнала, I_i – мощность помех в канале, W – ширина полосы частот, N_0 – спектральная плотность шума. Это выражение учитывает, как физические, так и технические параметры канала, включая расстояние между узлами, атмосферные и другие внешние воздействия, а также характеристики помех и шума.

Для моделирования процессов ожидания обслуживания и вычисления задержки в очереди используется стохастическая модель M/M/1. Если узел смоделирован как M/M/1-система, то средняя задержка в очереди определяется как:

$$T_{i,q}^{queue} = \frac{\rho_{i,q}}{\mu_{i,q}(1 - \rho_{i,q})},$$

где $\mu_{i,q}$ – средняя интенсивность обслуживания, $\rho_{i,q}$ – коэффициент загрузки узла.

Для вычисления полной задержки необходимо учитывать также время обработки задачи на EN или FN:

$$\tau_{i,q}^{comp} = \frac{c_i}{f_{i,q}},$$

где c_i – вычислительная сложность задачи (в CPU-циклах), $f_{i,q}$ – тактовая частота EN или FN.

После завершения обработки необходимо рассчитать время передачи результата обратно на OBU:

$$T_{i,q}^{dd} = \frac{l_{i,q}^{res}}{u_{i,q}^{downlink}},$$

где $l_{i,q}^{res}$ – объём выходных данных, $u_{i,q}^{downlink}$ – пропускная способность канала связи между OBU и выбранным EN или FN для выгрузки.

Учитывая все перечисленные компоненты, можно сформировать общую задержку выполнения i -й подзадачи.

$$T_{i,q} = T_{i,q}^{id} + T_{i,q}^{queue} + \tau_{i,q}^{comp} + T_{i,q}^{dd}.$$

В ряде приложений, выполнение дальнейших операций возможно только после получения полных результатов обработки задачи, поэтому стоит учитывать ограничение на задержку следующего вида:

$$T_q^{total} = \max_i(T_{i,q}).$$

3.3. Вычислительная модель энергетических затрат. Одним из оптимизируемых параметров рассматриваемой задачи является величина энергетических затрат на обслуживание функционирования системы OBU-RSU-EC-CLOUD. С ростом интенсивности движения и увеличением числа запросов ожидается увеличение количества вычислений и, как следствие, рост величины энергетических затрат, необходимых для функционирование инфокоммуникационной сети.

Каждое транспортное средство a_k оснащено ОВУ с ограниченным энергетическим ресурсом.

Будем считать, что на передачу, обработку и прием данных энергия затрачивается с КПД равным 1, то есть без внешних потерь. Расход энергии складывается из трех компонент:

$$E_i^{total} = E_i^{local} + E_i^{offload} + E_{i,q}^{comp},$$

где E_i^{local} – энергии локальных вычислений, $E_i^{offload}$ – энергия на передачу данных, $E_{i,q}^{comp}$ – энергии туманных вычислений.

Рассмотрим более подробно каждое из слагаемых.

1. При расчете локального энергопотребления важно учитывать три фактора: коэффициент энергоэффективности ОВУ h_i^{loc} , тактовую частоту процессора и вычислительную сложность задачи в циклах CPU.

$$E_i^{local} = h_i^{loc} \cdot c_i \cdot (f_i^{loc})^2.$$

2. Энергии передачи напрямую зависит от мощности передатчика и времени обработки запроса, то есть

$$E_i^{offload} = p_i \cdot T_{i,q}^{td}.$$

3. Подсчет затрат энергии на проведение расчетов на удаленном вычислите рассчитываются аналогично:

$$E_{i,q}^{comp} = h_{i,q}^{off} \cdot c_i \cdot (f_{i,q}^{off})^2.$$

Общий баланс энергии ОВУ в момент времени t описывается выражением:

$$E^{total} = \sum_{i=1}^N (E_i^{local} + E_i^{offload} + E_{i,q}^{comp}).$$

3.4. Модель оценки ETA с учетом ограничений. Построение маршрутов в ИТС традиционно осуществляется на основе минимизации функции стоимости, определяемой суммарным временем проезда по участкам дорожной сети. Такая сеть формализуется в виде ориентированного графа $G = (V, R)$. Каждый маршрут моделируется как путь на графе, состоящий из последовательности рёбер и переходов между ними.

Для поиска оптимального маршрута используется алгоритм A^* , который при наличии эвристической функции обеспечивает быстрое нахождение пути с минимальными издержками. Однако на практике маршруты, построенные только по параметру минимального времени, могут не соответствовать пользовательским ожиданиям: включать, например, неудобные повороты, заезды во дворы или второстепенные улицы. Это связано с тем, что традиционные метрики не учитывают субъективное восприятие удобства и привычки водителей.

С целью повышения качества маршрутов в модель вводятся дополнительные компоненты, отражающие психологические и поведенческие предпочтения водителей. Такие компоненты реализуются в виде штрафов, то есть корректирующих добавок к функции стоимости. Различают два типа ограничений:

1. мягкие ограничения – например, штрафы за выполнение разворота на перекрёстке или проезд по участку с плохим покрытием;

2. жёсткие ограничения – полностью исключающие определённые рёбра из рассмотрения (например, физически закрытые участки).

Функция ожидаемого времени прибытия в расширенном виде принимает следующий вид:

$$ETA(route) = \sum_{i=1}^{n_1} \frac{t(edge_i)}{f(p_{edge_i})} + \sum_{i=1}^{n_2} c^*(turn_i) + \sum_{i=1}^{n_3} r_i^*,$$

где t – базовое время проезда по участку дороги, при этом

$$c^*(turn_i) = \frac{\Delta t_{turn_i}}{f_t(p_{turn_i})}, \quad \Delta t_{turn_i} \quad \text{– штраф за манёвр на повороте } i,$$

p_{turn_i}, p_{edge_i} – эмпирические вероятности прохождения соответствующих сегментов, полученные из пользовательских данных, $f(\bullet), f_t(\bullet)$ – функции веса, штраф за редко используемые пути, r_i^* – дополнительные (контекстные) штрафы.

Для получения эмпирических вероятностей используется сопоставление маршрутов, сгенерированных системой, с фактическими треками движения пользователей (GPS-данными). Если маршрут и реальный трек совпадают на данном участке, это увеличивает значение p_{edge_i} , и, как следствие, снижает относительный вес соответствующего ребра при последующих расчётах. Аналогично оцениваются предпочтения при поворотах.

Данный подход предполагает итеративную коррекцию модели: на каждом этапе строятся маршруты, сравниваются с фактическими треками, обновляются значения p_{edge_i} и p_{turn_i} и уточняется функция стоимости. Целью такого итерационного процесса является минимизация различия между построенными маршрутами и поведением реальных пользователей. При этом система сохраняет гибкость и возможность адаптации к изменяющимся дорожным условиям.

Таким образом, рассмотренный подход сочетает традиционные алгоритмы маршрутизации с эмпирическими оценками пользовательского поведения, реализуя гибкий механизм адаптации маршрутов к реальным условиям и предпочтениям, повышая как объективную эффективность, так и субъективное восприятие качества маршрутов.

3.5. Формулировка задачи баланса. Объединяя три ключевых параметра – общую задержку, энергопотребление и ETA можно сформулировать многопараметрического уравнение баланса:

$$\min_{q \in \{e, f\}} \mathfrak{J} = \min_{q \in \{e, f\}} \left(\omega_1 T_{q, norm}^{total} + \omega_2 E_{q, norm}^{total} + (1 - \omega_1 - \omega_2) ETA_{norm} \right),$$

где $q \in \{e, f\}$ показывает какая модель взаимодействия рассматривается, $\omega_1, \omega_2 \in [0, 1]$, $\omega_1 + \omega_2 \leq 1$ – приоритетные веса каждой из характеристик. Индекс *norm* означает нормирование каждого ключевого аспекта уравнения баланса. Варьирование коэффициентов ω_1, ω_2 позволяет найти относительный баланс по вкладу компонент в целевую функцию относительно своих минимальных значений.

4. Результаты численного моделирования. Численные результаты строятся на основе ранее полученных данных моделирования. В предыдущих исследованиях [3, 4] авторами была определена средняя величина потерь пакетов для системы, передающей сообщения формата САМ, – эти значения использованы как базовый ориентир. В настоящей работе проводится дополнение модели оценкой

того, как сеть будет вести себя при передаче видеоданных в аналогичных условиях. Для этого, далее проводится анализ предельных возможностей системы при передаче видеоданных, включая определение зон устойчивой работы и точек деградации качества при росте числа подключённых машин. Такой подход позволяет понять, как изменяются характеристики трафика при переходе от передачи коротких телеметрических сообщений к более ресурсоёмким видеопотокам и сопоставить поведение системы в обоих сценариях.

Условия для моделирования остались неизменными: при формировании маршрута каждое OBU определяет целевую точку назначения, которая остаётся неизменной в течение всего пути. Путь к цели может адаптироваться в процессе движения: при обнаружении затора на участке дороги выполняется перестроение маршрута с использованием алгоритма A^* , что позволяет учитывать локальные изменения трафика. Источниками заторов в модели выступают только заранее определённые события – замедления или кратковременные остановки транспортных средств (с вероятностью 1:10 на 1–5 секунд), создающие цепочку пробок. При этом не моделируются непредсказуемые внешние воздействия (экстремальные погодные условия, массовые эвакуации, появление новых объектов в сети), что является одним из ограничений модели.

Для обеспечения достоверности моделирования сетевого трафика были проведены эксперименты, заключающиеся в физической передаче видеоданных с последующим анализом сетевого трафика с помощью программного инструмента Wireshark. В результате экспериментов было зафиксировано общее количество сетевых пакетов, необходимых для передачи заданного видеофайла с заранее установленными параметрами скорости передачи данных и битрейта. Именно эти экспериментально полученные данные служат ориентиром для имитации передачи пакетов в модели.

В рамках эксперимента, для задания видеотрафика, используется тестовая видеопоследовательность «Akiyo», закодированная с использованием кодека libx264 при среднем битрейте 500 кбит/с [27]. Структура GOP представлена в следующем виде: I-, B- и P-кадры чередуются в определённой последовательности. Согласно анализу, получены следующие количественные характеристики:

I-кадров: 2, P-кадров: 216, B-кадров: 82.

Ниже приведена последовательность типов кадров (фрагмент выборки): «IBPPPPBPPP...». Такое распределение отражает высокую

плотность межкадрового предсказания: большинство кадров являются Р- или В-типов, опирающихся на один или два опорных кадра соответственно. Учитывая наличие всего двух I-кадров на весь видеопоток, утрата любого из них приведёт к невозможности декодирования целых фрагментов видео между GOP.

Для оценки параметров передаваемого видеопотока дополнительно зафиксированы следующие характеристики:

- Bitrate (заданный): 500 кбит/с
- Количество переданных пакетов: 581
- Средняя скорость передачи: 498.66 кбит/с
- Общий объём переданных данных: 4 986 624 бит (~ 623 328 байт).

При анализе передачи видеопотока с различными значениями битрейта необходимо учитывать, что увеличение битрейта приводит к росту объёма передаваемых данных, а также числа сетевых пакетов, необходимых для доставки полного файла, что отражено на рисунке 2.

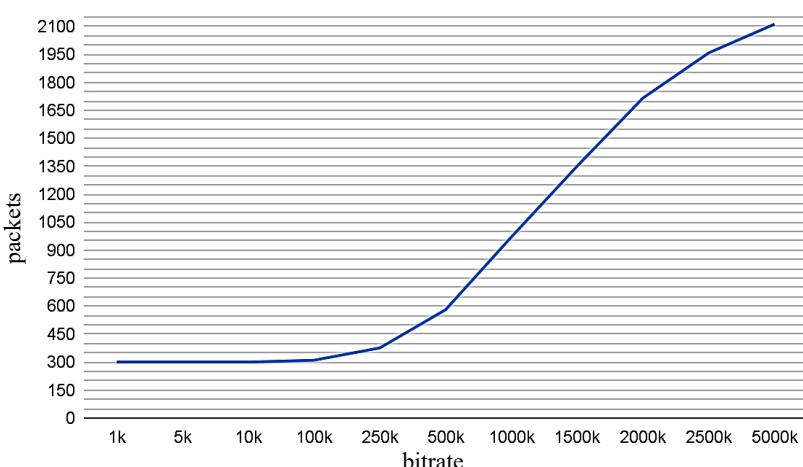


Рис. 2. Зависимость количества пакетов от битрейта

Существенное значение имеет соотношение между заданным битрейтом видеопотока и доступной скоростью получения данных конечным узлом. В случае, если пропускная способность канала оказывается ниже требуемого битрейта, наблюдаются значительные потери пакетов, приводящие к снижению качества видеопотока вплоть до его полной непригодности к использованию.

При проведении численного моделирования рассматривается беспроводной канал шириной 20 МГц с применением протокола IEEE 802.11bd. Выбор схемы модуляции осуществляется с учетом отношения сигнал/шум (SNR), которое определяет способность системы различать полезный сигнал на фоне фонового шума. Повышенное значение SNR свидетельствует о более чистом приёме сигнала, что позволяет применять модуляции более высокого порядка и, соответственно, достигать большей скорости передачи данных [28]. Низкоуровневые модуляции (BPSK, QPSK) обеспечивают стабильную передачу на малом количестве пользователей, но быстро деградируют по мере роста числа машин. Модуляции высокого порядка (например, 1024-QAM 3/4) обеспечивают максимальную пропускную способность на одного пользователя, но требуют высоких значений SNR, вследствие чего применимы только при минимальной нагрузке или высококачественном канале.

На рисунке 3 представлена предельная способность сети по передаче видеопотока с заданным битрейтом в зависимости от количества обслуживаемых транспортных средств, подключённых к одной RSU.

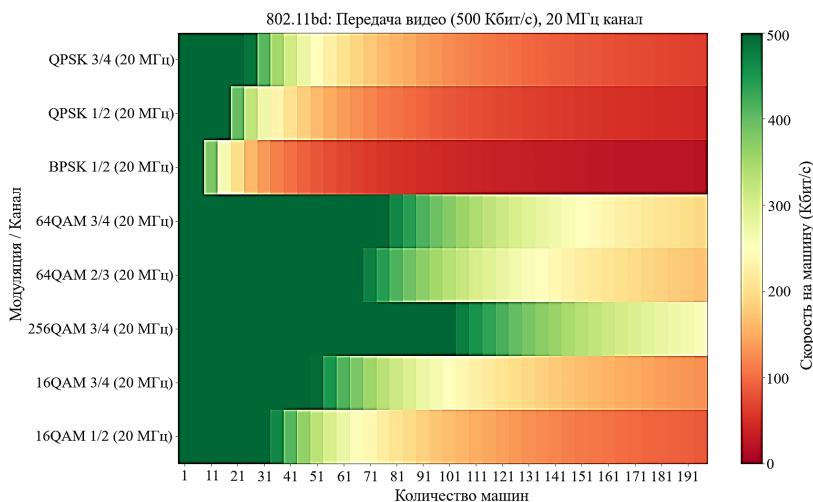


Рис. 3. Предельная способность сети по передаче видеопотока с заданным битрейтом на одно RSU

Зелёная зона (скорость передачи более 500 Кбит/с) указывает на участки, где возможна устойчивая передача видеопотока без потерь.

Здесь используются как устойчивые схемы модуляции (например, QPSK 3/4), так и более производительные (например, 256-QAM 3/4) при ограниченном числе машин.

Жёлтая зона (200–400 Кбит/с) свидетельствует о частичной деградации качества: при превышении определённого порога количества пользователей модуляция становится недостаточно эффективной для поддержания необходимого битрейта.

Красная зона (менее 100 Кбит/с) демонстрирует непригодность схемы модуляции для данной нагрузки: при числе машин выше определённого предела скорость падает настолько, что не может обеспечить даже базовое качество видео.

Энергопотребление при передаче данных в беспроводных сетях определяется не только продолжительностью передачи, но и эффективностью используемой модуляции, а также доступной пропускной способностью канала. На рисунке 4 визуализированы энергетические затраты на передачу видеопотока объёмом 0.5 Мбит при использовании канала шириной 20 МГц и протокола IEEE 802.11bd.

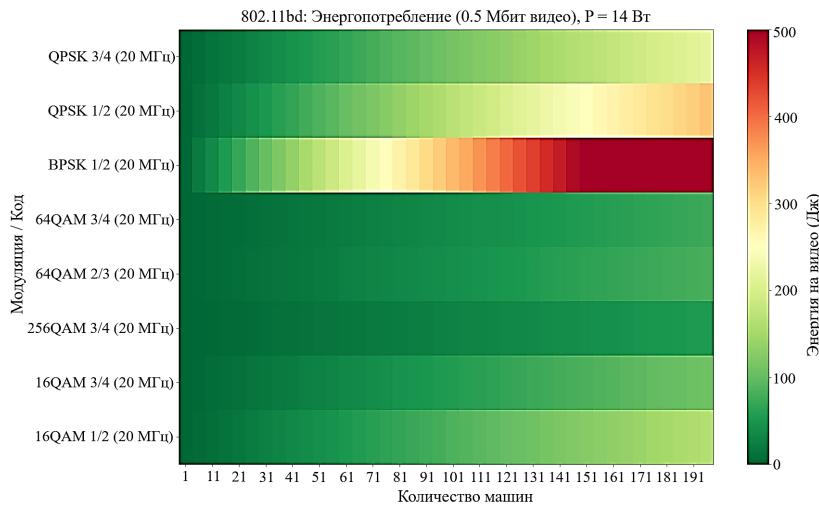


Рис. 4. Энергетические затраты на передачу видеопотока

Значения на графике интерпретируются следующим образом: чем выше энергия на одно видео (в джоулях), тем менее энергоэффективна схема передачи при заданной нагрузке. Заметно, что схемы с низкоуровневыми модуляциями (например, BPSK 1/2 и

QPSK 1/2) демонстрируют существенно более высокое потребление энергии при увеличении количества подключённых устройств. Это объясняется необходимостью более длительной передачи, обусловленной низкой физической скоростью передачи данных (PHY-rate), что при фиксированной мощности приводит к росту общего энергопотребления. В отличие от них, высокочувствительные модуляции, такие как 64-QAM и 256-QAM, позволяют существенно сократить энергетические затраты за счёт более высокой пропускной способности, даже при увеличенном числе пользователей. Однако эти схемы требуют стабильного канала и высокого значения SNR, что ограничивает их применение в условиях подвижной среды и радиопомех. Таким образом, для достижения оптимального баланса между энергоэффективностью и стабильностью связи, выбор схемы модуляции должен быть адаптивным, опирающимся как на текущую загрузку RSU, так и на измеренные характеристики канала.

Рассмотрим значения параметров моделирования. Для задержки прибытия mRSU, учитывая динамическое перераспределение нагрузки, показатель ETA применяются следующие допущения: согласно ранее опубликованному результату [16], прибытие mRSU в перегруженную зону позволяет достичь разгрузки до 20%. Исходя из этого, вероятность прибытия mRSU в зону покрытия конкретного OBU принимается равной 0.2 (20%). В случае, если mRSU уже находится в зоне, показатель ETA принимается равным нулю. Для оставшихся 80% вероятность распределяется по нормальному закону, при этом предельное значение расстояния установлено на уровне 1.5 км. При средней скорости движения mRSU, составляющей 30 км/ч, формируется аппроксимация временного окна прибытия, используемая в вычислениях задержки.

Передача видеопотока осуществляется с битрейтом 500 Кбит/с и длительностью 10 секунд, что формирует общий размер данных, равный 0.5 Мбит. Расчёт энергетических затрат на обработку и передачу видеопотока основывается на формулах из пункта 3.3., где

- Тактовая частота центрального процессора RSU $716 \cdot 10^6$ Гц.
- Средняя потребляемая мощность узла 14 Вт.
- Количество процессорных тактов на обработку одного байта информации – 500.

Общее количество обслуживаемых транспортных средств (OBU) в пределах одной станции RSU колеблется от 20 до 30. Используемый канал связи имеет ширину 20 МГц. При этом уровень отношения сигнал/шум на участке принимается равным 10 дБ, что

накладывает ограничения на допустимые схемы модуляции и снижает спектральную эффективность по сравнению с высокочастотными участками.

Для комплексного анализа характеристик сети в условиях различной нагрузки важно учитывать не только параметры задержки и пропускной способности, но и надёжность передачи данных. Одним из ключевых показателей, характеризующих надёжность радиоканала, является коэффициент потерь пакетов (Packet Error Rate, PER). Он отражает долю пакетов, не доставленных корректно до получателя, и непосредственно влияет на целостность медиапотока, особенно в приложениях реального времени – таких как видеотрансляции. На рисунке 5 отображена зависимость PER от количества подключённых транспортных средств (OBU) к одной RSU.

Зависимость PER от количества машин на RSU

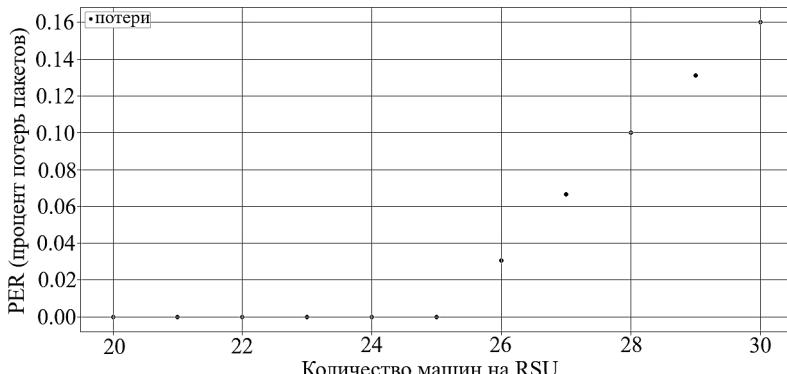


Рис. 5. Зависимость PER от количества подключённых транспортных средств (OBU) к одной RSU

Как видно из графика, при количестве машин менее 25 наблюдается практически полное отсутствие потерь, что свидетельствует о достаточной пропускной способности радиоканала и эффективной обработке пакетов на уровне MAC (Media Access Control, MAC) и PHY. Однако начиная с 26 и особенно после 27 машин на RSU наблюдается резкий рост PER. Уже при 28 устройствах потери достигают 10%, а при 30 – превышают 16%, что является критическим значением для мультимедийного трафика. Такие потери делают видеопоток практически непригодным для потребления, вызывая артефакты и прерывания воспроизведения.

Полученные результаты указывают на наличие порогового значения нагрузки на RSU, превышение которого приводит к экспоненциальному росту потерь пакетов. Для устойчивой передачи видео при заданных параметрах канала (20 МГц, 802.11bd, битрейт 500 Кбит/с), допустимое количество одновременных подключений к одной базовой станции не должно превышать 25 машин. Это значение должно учитываться при проектировании архитектуры сетей V2X и распределении нагрузки между RSU и mRSU.

В исследовании были рассмотрены следующие варианты:

- Равный приоритет [0.33, 0.33, 0.33] – Сценарий, в котором система стремится сбалансировать все параметры без акцента на какой-либо из них. Этот подход универсален, но может уступать в экстремальных условиях.
- Приоритет **DELAY** [0.5, 0.25, 0.25] – Нацелен на минимизацию задержек, что особенно актуально для критически чувствительных к времени приложений (например, управления движением или видеоконференций в реальном времени).
- Приоритет **ENERGY** [0.25, 0.5, 0.25] – Подходит для сценариев с ограниченными энергетическими ресурсами, например, при длительной автономной работе RSU.
- Приоритет **ETA** [0.25, 0.25, 0.5] – Предпочтителен в условиях высокой мобильности или частого прибытия/ухода mRSU, так как минимизация ETA позволяет оперативно перераспределять нагрузку и предсказывать оптимальные интервалы передачи.
- Без ETA [0.5, 0.5, 0] – Этот подход исключает параметр ETA, что снижает способность системы учитывать динамику мобильных узлов. Как показывают результаты, именно этот вариант демонстрирует наихудшие показатели в условиях высокой плотности трафика.

На рисунке 6 отображена зависимость метрики FFF (общая задержка – «Delay», энергопотребление – «Energy», ETA) от количества машин, подключённых к одной RSU. Можно отметить, что при небольшом числе подключённых машин (20–23) различия между стратегиями невелики, что обусловлено низкой загрузкой канала и отсутствием существенных конфликтов в передаче. Однако с увеличением числа машин эффективность стратегии «Без ETA» (фиолетовый) быстро деградирует: метрика FFF существенно возрастает, что свидетельствует о снижении общей эффективности передачи. В то же время стратегии с учётом ETA демонстрируют стабильно более низкие значения FFF, особенно в сценарии с приоритетом ETA (красный цвет), что говорит о преимуществе в

условиях ограниченного ресурса и подвижной инфраструктуры. Стратегия с приоритетом по энергопотреблению (зелёный) показывает среднюю эффективность, уступая по задержке и ожидаемому времени прибытия mRSU.

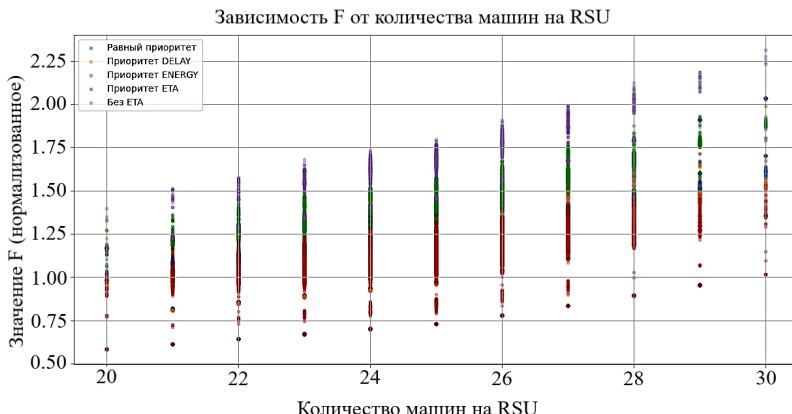


Рис. 6. Зависимость метрики FFF от количества машин, подключённых к одной RSU

На рисунке 7 представлена связь между метрикой FFF и уровнем потерь пакетов (PER).

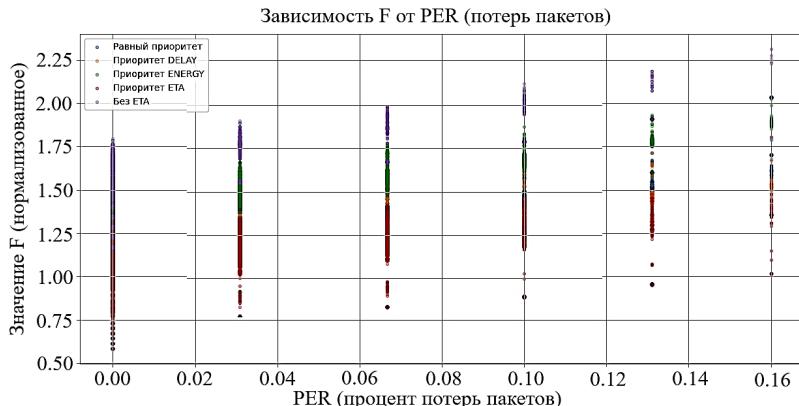


Рис. 7. Связь между метрикой FFF и уровнем потерь пакетов (PER)

Здесь отчётливо прослеживается, что при возрастании PER значение FFF также увеличивается, особенно в сценариях, не

учитывающих ETA. Это подтверждает, что потери пакетов критически влияют на общую производительность системы. Сценарии, учитывающие ETA (особенно с его приоритетом), демонстрируют наименьшее увеличение FFF при росте PER, что подчёркивает устойчивость этих подходов к ухудшению условий канала. В противоположность им, равный приоритет и особенно «Без ETA» теряют эффективность при даже умеренных потерях, что делает их менее подходящими для подвижных и нестабильных сетей.

5. Заключение. В представленной работе разработана математическая модель многопараметрической балансировки параметров функционирования V2X-системы, направленная на совместную оптимизацию трёх ключевых характеристик: задержки передачи, энергопотребления и ожидаемого времени прибытия вычислительного ресурса. Центральной задачей исследования стало построение уравнения баланса, отражающего взаимосвязь между этими параметрами в условиях ограниченной пропускной способности и переменной сетевой нагрузки.

Вклад авторов можно обобщить следующим образом:

1. Представлено обобщение входных данных оптимизационной задачи балансировки нагрузки для системы OBU-RSU-EC-CLOUD с классификацией их на компоненты: универсальные данные (влияющие на энергопотребление и общую задержку), и данные, ориентированные на мобильность системы.

2. Предложена задача оптимизации балансировки нагрузки и распределения ресурсов, при этом цель оптимизации заключается в минимизации общей задержки ответа для всех задач в период оптимизации.

3. Представлены результаты моделирования на примере балансировки нагрузки при выгрузке данных типа «Real-Time Video Streaming» по средствам протокола RTP, подтверждающие рациональность использования предложенного подхода к решению поставленной задачи оптимизации.

Модель формализует структуру транспортной системы в виде ориентированного графа, с заданными маршрутами движения, размещением стационарных (RSU) и мобильных (mRSU) вычислительных узлов, а также параметрами обмена видео между ними и терминальными устройствами (OBU). Имитационная модель [25], созданная в рамках работы, позволила рассчитать задержки, потери и энергозатраты при различных сценариях передачи, учитывающих ширину канала, количество обслуживаемых устройств и уровень сигнала (SNR). Отдельные параметры, использованные в

уравнении, были получены в результате моделирования, другие – верифицированы на основе ранее опубликованного результата [4]. Эти данные были скомбинированы и интегрированы в аналитическую модель.

Для оценки эффективности передачи использовалась многопараметрическая функция, позволяющая варьировать весовые коэффициенты между тремя показателями. Это дало возможность адаптировать поведение системы под конкретные условия эксплуатации: например, в условиях высокой плотности трафика особую значимость приобретает ETA, тогда как в условиях энергодефицита целесообразно смещать приоритет в сторону минимизации энергопотребления. Введённая метрика FFF обеспечила количественную оценку различных сценариев балансировки, а численные эксперименты подтвердили применимость подхода в задачах выбора оптимального маршрута и ресурса передачи.

Проведённое исследование показало, что функция баланса применима как к телеметрическим, так и к мультимедийным (видеопоток) сценариям, адекватно отражая изменения производительности системы при смене типа трафика. Использование ранее измеренных параметров потерь для телеметрических сообщений в моделировании видеопотока позволило провести прямое сопоставление и подтвердить универсальность предложенного подхода. Полученные результаты важны для проектирования V2X-систем, способных стablyно работать при разных профилях трафика и уровнях нагрузки.

Таким образом, в результате исследования была сформирована прикладная и формализованная модель баланса в V2X-системах, обеспечивающая обоснованную оценку эффективности передачи данных с учётом комплексных ограничений. Полученные результаты могут быть использованы при построении архитектур интеллектуальных транспортных систем, включающих распределённые вычислительные механизмы, и при разработке адаптивных стратегий управления нагрузкой в реальных условиях эксплуатации. В будущих работах авторами планируется постановка серии имитационных тестов на комплекте V2X-оборудования для оценки эффективности разработанной модели.

Литература

1. Singh M., Baranwal G. Quality of Service (QoS) in Internet of Things // Proceedings of 3rd International Conference on Internet of Things: Smart Innovation and Usages (IoT-SIU). 2018. pp. 1–6.
2. Singh S.P., Singh P., Diwakar M., Kumar P. Improving quality of service for Internet of Things (IoT) in real life application: A novel adaptation-based Hybrid Evolutionary Algorithm // Internet of Things. 2024. vol. 27.

3. Vladyko A., Tambovtsev G., Podgornaya E., Chelloug S.A., Alkanhel R., Plotnikov P. Cluster Based Vehicle-to-Everything Model with a Shared Cache // Mathematics. 2023. vol. 11. no. 13.
4. Vladyko A., Plotnikov P., Tambovtsev G. Simulation-Based Evaluation of V2X System with Variable Computational Infrastructure // Network. 2025. vol. 5. no. 1.
5. Aldhanhani T., Abraham A., Hamidouche W., Shaaban M. Future Trends in Smart Green IoV: Vehicle-to-Everything in the Era of Electric Vehicles // IEEE Open Journal of Vehicular Technology. 2024. vol. 5. pp. 278–297.
6. Dhinesh Kumar R., Rammohan A. Revolutionizing Intelligent Transportation Systems with Cellular Vehicle-to-Everything (C-V2X) technology: Current trends, use cases, emerging technologies, standardization bodies, industry analytics and future directions // Vehicular Communications. 2023. vol. 43. DOI: 10.1016/j.vehcom.2023.100638.
7. Kong X., Wu Y., Wang H., Xia F. Edge Computing for Internet of Everything: A Survey // IEEE Internet of Things Journal. 2022. vol. 9. no. 23. pp. 23472–23485.
8. Mukherjee M., Shu L., Wang D. Survey of Fog Computing: Fundamental, Network Applications, and Research Challenges // IEEE Communications Surveys and Tutorials. 2018. vol. 20. no. 3. pp. 1826–1857.
9. Caiazza C., Giordano S., Luconi V., Vecchio A. Edge computing vs centralized cloud: Impact of communication latency on the energy consumption of LTE terminal nodes // Computer Communications. 2022. vol. 194. pp. 213–225.
10. Ruchika Chhillar R.S. Performance Evaluation of Hybrid Cloud-Fog Computing Architectures in Smart Home IoT Environments: A Comparative Simulation Study across Multiple Tools // Journal of Grid Computing. 2025. vol. 23. DOI: 10.1007/s10723-025-09802-9.
11. Плотников П.В., Владыко А.Г. Анализ подходов к оптимизации V2X-систем: кластеризация, граничные и туманные вычисления // Труды учебных заведений связи. 2024. Т. 10. № 3. С. 7–22.
12. Bali R.S., Kumar N., Rodrigues J.J. Clustering in vehicular ad hoc networks: taxonomy, challenges and solutions // Vehicular Communications. 2014. vol. 1. no. 3. pp. 134–152.
13. Cooper C., Franklin D., Ros M., Safaei F., Abolhasan M. A. Comparative Survey of VANET Clustering Techniques // IEEE Communications Surveys and Tutorials. 2016. vol. 19. no. 1. pp. 657–681.
14. Raza S., Wang S., Ahmed M., Anwar M.R. A survey on vehicular edge computing: architecture, applications, technical issues, and future directions // Wireless Communications and Mobile Computing. 2019. vol. 2019(1).
15. Hou X., Li Y., Chen M., Wu D., Jin D., Chen S. Vehicular Fog Computing: A Viewpoint of Vehicles as the Infrastructures // IEEE Transactions on Vehicular Technology. 2016. vol. 65. no. 6. pp. 3860–3873.
16. Plotnikov P.V., Tambovtsev G.I., Vladyko A.G. Evaluating the Performance of Using Mobile Roadside Units for Task Offloading in V2X Systems // Proceedings of the Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED). 2024. pp. 1–4.
17. Elgendi I.A., Muthanna A., Alshahrani A., Hassan D.S.M., Alkanhel R., Elkawkagy M. Optimizing Energy Efficiency in Vehicular Edge-Cloud Networks Through Deep Reinforcement Learning-Based Computation Offloading // IEEE Access. 2024. vol. 12. pp. 191537–191550.
18. Клименко А.Б. Двухкритериальный метод обеспечения ресурсосбережения в краевом и туманном слоях сети // Advanced Engineering Research (Rostov-on-Don). 2023. Т. 23. № 1. С. 85–94.
19. Elgendi I.A., Khakimov A., Muthanna A. Energy-Efficient Framework for Task Caching and Computation Offloading in Multitier Vehicular Edge-Cloud Systems // Lecture Notes in Computer Science. Springer. 2025. vol. 15460. pp. 42–53.

-
20. Zhang G., Shen F., Yang Y., Qian H., Yao W. Fair Task Offloading among Fog Nodes in Fog Computing Networks // Proceedings of IEEE International Conference on Communications (ICC). 2018. pp. 1–6. DOI: 10.1109/ICC.2018.8422316.
21. Zhang G., Shen F., Liu Z., Yang Y., Wang K., Zhou M.T. FEMTO: Fair and Energy-Minimized Task Offloading for Fog-Enabled IoT Networks // IEEE Internet of Things Journal. 2019. vol. 6. no. 3. pp. 4388–4400.
22. Abuelenin S.M., Abul-Magd A.Y. Empirical study of traffic velocity distribution and its effect on VANETs connectivity // Proceedings of 2014 International Conference on Connected Vehicles and Expo (ICCVE). 2014. pp. 391–395.
23. Schulzrinne H., Rao A., Lanphier R., Westerlund M., Stiemerling M. Real-Time Streaming Protocol Version 2.0. RFC 7826. 2016.
24. Lee J., Shin I., Park H. Adaptive Intra-Frame Assignment and Bit-Rate Estimation for Variable GOP Length in H.264 // IEEE Transactions on Circuits and Systems for Video Technology. 2006. vol. 16. no. 10. pp. 1271–1279.
25. Plotnikov P., Tambovtsev G., Vladyko A. VANET Ver. 2.0.0 – Software Module for Modeling the Interaction of Edge Devices, 2024. URL: <https://github.com/quanuhb/VANET> (дата обращения: 11.09.2025).
26. Iliopoulos C., Iossifides A., Foh C.H., Chatzimisios P. IEEE 802.11 bd for Next-Generation V2X Communications: From Protocol to Services // IEEE Communications Standards Magazine. 2025. vol. 9. no. 2. pp. 88–98.
27. Jiang X., He P., Sun T., Xie F., Wang S. Detection of Double Compression With the Same Coding Parameters Based on Quality Degradation Mechanism Analysis // IEEE Transactions on Information Forensics and Security. 2017. vol. 13. no. 1. pp. 170–185.
28. Xue S., Gong S., Li X. A Comparative Study of IEEE 802.11bd and IEEE 802.11p on the Data Dissemination Properties in Dynamic Traffic Scenarios // Applied Sciences. 2024. vol. 14. no. 5.

Плотников Павел Владимирович — канд. физ.-мат. наук, доцент, заведующий кафедрой, кафедра высшей математики, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича (СПбГУТ). Область научных интересов: математическое моделирование, телекоммуникационные системы транспортных средств, *vehicle-to-everything*. Число научных публикаций — 57. plotnikov.pv@sut.ru; проспект Большевиков, 22/1, 193232, Санкт-Петербург, Россия; р.т.: +7(812)305-1218.

Тамбовцев Глеб Ильич — аспирант, инженер, студенческое конструкторское бюро, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича (СПбГУТ). Область научных интересов: программная инженерия, математическое моделирование, телекоммуникационные системы транспортных средств. Число научных публикаций — 17. tambovtsev.gi@sut.ru; проспект Большевиков, 22/1, 193232, Санкт-Петербург, Россия; р.т.: +7(812)326-3163.

Владыко Андрей Геннадьевич — канд. техн. наук, доцент, декан факультета, факультет радиоэлектронных систем и робототехники, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича (СПбГУТ). Область научных интересов: телекоммуникационные системы транспортных средств, *vehicle-to-everything*, граничные и туманные вычисления. Число научных публикаций — 158. vladyko@sut.ru; проспект Большевиков, 22/1, 193232, Санкт-Петербург, Россия; р.т.: +7(812)305-1263.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 24-29-00304, <https://rscf.ru/project/24-29-00304/>.

P. PLOTNIKOV, G. TAMBOVTSEV, A. VLADYKO

**MATHEMATICAL MODEL OF MULTI-CRITERIA BALANCING
OF V2X-SYSTEM PARAMETERS**

Plotnikov P., Tambovtsev G., Vladyko A. Mathematical Model of Multi-Criteria Balancing Of V2X-System Parameters.

Abstract. The development of intelligent transportation systems and the introduction of V2X (Vehicle-to-Everything) architecture place high demands on the characteristics of network communication, such as minimum latency, high reliability, and energy efficiency. At the same time, a decrease in one of the parameters entails an increase in another, which makes the task of their balanced tuning relevant and practically significant. It is especially important to consider not only the total delay (communication network delay and computational delay) and energy consumption, but also the expected arrival time of a mobile computing node based on a vehicle, which is an integral indicator of service quality in a dynamically changing environment. In this paper, we propose a mathematical model for multi-parameter optimization of V2X-system operation parameters that takes into account three interrelated indicators: total delay, energy consumption, and expected arrival time. The model formalizes the structure of the transport system as a directed graph with specified traffic routes, the location of stationary and mobile computing nodes of the transport infrastructure, and the parameters of video data exchange between them and terminal devices. The model is presented as an optimization problem and allows tuning the system according to external conditions and application goals. Simulation modeling methods with realistic vehicle traffic scenarios and variable network load are used as a research tool. The results of numerical experiments demonstrate that the use of the proposed model will allow achieving more balanced modes of system operation, reducing the total delays and energy consumption without deterioration of the arrival time parameters. Compared to traditional approaches based on single- or two-criteria optimization, the proposed method provides greater adaptability and stability of V2X systems to changing operating conditions. The findings can be useful for researchers in designing and implementing energy-efficient and reliable distributed architectures in modern transportation networks.

Keywords: V2X systems, multi-parameter optimization, mathematical modeling, intelligent transportation systems, edge computing, fog computing.

References

1. Singh M., Baranwal G. Quality of Service (QoS) in Internet of Things. Proceedings of 3rd International Conference on Internet of Things: Smart Innovation and Usages (IoT-SIU). 2018. pp. 1–6.
2. Singh S.P., Singh P., Diwakar M., Kumar P. Improving quality of service for Internet of Things (IoT) in real life application: A novel adaptation-based Hybrid Evolutionary Algorithm. Internet of Things. 2024. vol. 27.
3. Vladyko A., Tambovtsev G., Podgornaya E., Chelloug S.A., Alkanhel R., Plotnikov P. Cluster Based Vehicle-to-Everything Model with a Shared Cache. Mathematics. 2023. vol. 11, no. 13.
4. Vladyko A., Plotnikov P., Tambovtsev G. Simulation-Based Evaluation of V2X System with Variable Computational Infrastructure. Network. 2025. vol. 5. no. 1.
5. Aldhanhani T., Abraham A., Hamidouche W., Shaaban M. Future Trends in Smart Green IoV: Vehicle-to-Everything in the Era of Electric Vehicles. IEEE Open Journal of Vehicular Technology. 2024. vol. 5. pp. 278–297.

-
6. Dhinesh Kumar R., Rammohan A. Revolutionizing Intelligent Transportation Systems with Cellular Vehicle-to-Everything (C-V2X) technology: Current trends, use cases, emerging technologies, standardization bodies, industry analytics and future directions. *Vehicular Communications*. 2023. vol. 43. DOI: 10.1016/j.vehcom.2023.100638.
 7. Kong X., Wu Y., Wang H., Xia F. Edge Computing for Internet of Everything: A Survey. *IEEE Internet of Things Journal*. 2022. vol. 9. no. 23. pp. 23472–23485.
 8. Mukherjee M., Shu L., Wang D. Survey of Fog Computing: Fundamental, Network Applications, and Research Challenges. *IEEE Communications Surveys and Tutorials*. 2018. vol. 20. no. 3. pp. 1826–1857.
 9. Caiazza C., Giordano S., Luconi V., Vecchio A. Edge computing vs centralized cloud: Impact of communication latency on the energy consumption of LTE terminal nodes. *Computer Communications*. 2022. vol. 194. pp. 213–225.
 10. Ruchika Chhillar R.S. Performance Evaluation of Hybrid Cloud-Fog Computing Architectures in Smart Home IoT Environments: A Comparative Simulation Study across Multiple Tools. *Journal of Grid Computing*. 2025. vol. 23. DOI: 10.1007/s10723-025-09802-9.
 11. Plotnikov P.V., Vladyko A.G. [Analysis of approaches to V2X-systems optimization: clustering, edge and fog computing]. *Trudy uchebnykh zavedenii sviazi – Proceedings of Telecommunication Universities*. 2024. vol. 10. no. 3. pp. 7–22. (In Russ.).
 12. Bali R.S., Kumar N., Rodrigues J.J. Clustering in vehicular ad hoc networks: taxonomy, challenges and solutions. *Vehicular Communications*. 2014. vol. 1. no. 3. pp. 134–152.
 13. Cooper C., Franklin D., Ros M., Safaei F., Abolhasan M. A. Comparative Survey of VANET Clustering Techniques. *IEEE Communications Surveys and Tutorials*. 2016. vol. 19. no. 1. pp. 657–681.
 14. Raza S., Wang S., Ahmed M., Anwar M.R. A survey on vehicular edge computing: architecture, applications, technical issues, and future directions. *Wireless Communications and Mobile Computing*. 2019. vol. 2019(1).
 15. Hou X., Li Y., Chen M., Wu D., Jin D., Chen S. Vehicular Fog Computing: A Viewpoint of Vehicles as the Infrastructures. *IEEE Transactions on Vehicular Technology*. 2016. vol. 65. no. 6. pp. 3860–3873.
 16. Plotnikov P.V., Tambovtsev G.I., Vladyko A.G. Evaluating the Performance of Using Mobile Roadside Units for Task Offloading in V2X Systems. *Proceedings of the Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)*. 2024. pp. 1–4.
 17. Elgendi I.A., Muthanna A., Alshahrani A., Hassan D.S.M., Alkanhel R., Elkawkagy M. Optimizing Energy Efficiency in Vehicular Edge-Cloud Networks Through Deep Reinforcement Learning-Based Computation Offloading. *IEEE Access*. 2024. vol. 12. pp. 191537–191550.
 18. Klimenko A.B. [A two-criteria method to ensure resource conservation in the edge and fog layers of the network]. *Advanced Engineering Research (Rostov-on-Don)*. 2023. vol. 23. no. 1. pp. 85–94.
 19. Elgendi I.A., Khakimov A., Muthanna A. Energy-Efficient Framework for Task Caching and Computation Offloading in Multitier Vehicular Edge-Cloud Systems. *Lecture Notes in Computer Science*. Springer. 2025. vol. 15460. pp. 42–53.
 20. Zhang G., Shen F., Yang Y., Qian H., Yao W. Fair Task Offloading among Fog Nodes in Fog Computing Networks. *Proceedings of IEEE International Conference on Communications (ICC)*. 2018. pp. 1–6. DOI: 10.1109/ICC.2018.8422316.
 21. Zhang G., Shen F., Liu Z., Yang Y., Wang K., Zhou M.T. FEMTO: Fair and Energy-Minimized Task Offloading for Fog-Enabled IoT Networks. *IEEE Internet of Things Journal*. 2019. vol. 6. no. 3. pp. 4388–4400.

22. Abuelenin S.M., Abul-Magd A.Y. Empirical study of traffic velocity distribution and its effect on VANETs connectivity. Proceedings of 2014 International Conference on Connected Vehicles and Expo (ICCVE). 2014. pp. 391–395.
23. Schulzrinne H., Rao A., Lanphier R., Westerlund M., Stiemerling M. Real-Time Streaming Protocol Version 2.0. RFC 7826. 2016.
24. Lee J., Shin I., Park H. Adaptive Intra-Frame Assignment and Bit-Rate Estimation for Variable GOP Length in H.264. IEEE Transactions on Circuits and Systems for Video Technology. 2006. vol. 16. no. 10. pp. 1271–1279.
25. Plotnikov P., Tambovtsev G., Vladko A. VANET Ver. 2.0.0 – Software Module for Modeling the Interaction of Edge Devices, 2024. Available at: <https://github.com/quanuhu/VANET> (accessed 11.09.2025).
26. Iliopoulos C., Iossifides A., Foh C.H., Chatzimisios P. IEEE 802.11 bd for Next-Generation V2X Communications: From Protocol to Services. IEEE Communications Standards Magazine. 2025. vol. 9. no. 2. pp. 88–98.
27. Jiang X., He P., Sun T., Xie F., Wang S. Detection of Double Compression With the Same Coding Parameters Based on Quality Degradation Mechanism Analysis. IEEE Transactions on Information Forensics and Security. 2017. vol. 13. no. 1. pp. 170–185.
28. Xue S., Gong S., Li X. A Comparative Study of IEEE 802.11bd and IEEE 802.11p on the Data Dissemination Properties in Dynamic Traffic Scenarios. Applied Sciences. 2024. vol. 14. no. 5.

Plotnikov Pavel — Ph.D., Associate Professor, Head of the department, Department of higher mathematics, The Bonch-Bruevich Saint Petersburg State University of Telecommunications (SPbSUT). Research interests: mathematical modeling, vehicular communication systems, vehicle-to-everything. The number of publications — 57. plotnikov.pv@sut.ru; 22/1, Bolshevik Ave., 193232, St. Petersburg, Russia; office phone: +7(812)305-1218.

Tambovtsev Gleb — Graduate student, engineer, Student design bureau, The Bonch-Bruevich Saint Petersburg State University of Telecommunications (SPbSUT). Research interests: software engineering, mathematical modeling, vehicular communication systems. The number of publications — 17. tambovcev.gi@sut.ru; 22/1, Bolshevik Ave., 193232, St. Petersburg, Russia; office phone: +7(812)326-3163.

Vladko Andrei — Ph.D., Associate Professor, Dean of the faculty, Faculty of radioelectronic systems and robotics, The Bonch-Bruevich Saint Petersburg State University of Telecommunications (SPbSUT). Research interests: vehicular communication systems, vehicle-to-everything, edge/fog computing. The number of publications — 158. vladko@sut.ru; 22/1, Bolshevik Ave., 193232, St. Petersburg, Russia; office phone: +7(812)305-1263.

Acknowledgements. This research was funded by the Russian Science Foundation, grant number 24-29-00304, <https://rscf.ru/en/project/24-29-00304/>.

А.А. АКИМОВ, Ю.А. ГНАТЕНКО, Р.Г. БОЛБАКОВ

**МНОГОУРОВНЕВАЯ СТРАТЕГИЯ БЕЗОПАСНОЙ
НАВИГАЦИИ И РАСПРЕДЕЛЕНИЯ РОЯ БПЛА
ДЛЯ МОНИТОРИНГА ЛЕСНЫХ ПОЖАРОВ**

Акимов А.А., Гнатенко Ю. А., Болбаков Р.Г. Многоуровневая стратегия безопасной навигации и распределения роя БПЛА для мониторинга лесных пожаров.

Аннотация. Лесные пожары являются одной из наиболее опасных и трудно прогнозируемых природных угроз, что требует постоянного мониторинга линии распространения огня в реальном времени. Традиционные средства, такие как спутниковая съемка или наземные наблюдательные посты, не обеспечивают необходимой оперативности и полноты данных. Перспективным решением становится использование роя беспилотных летательных аппаратов (БПЛА), однако их эффективная координация в условиях динамичной обстановки и ограниченных ресурсов связи и вычислений требует разработки специальных алгоритмов. В работе представлена многоуровневая стратегия управления роем БПЛА, объединяющая три механизма. Горизонтальная навигация реализуется методом искусственных потенциальных полей (Artificial Potential Field, APF), обеспечивающим притяжение к линии фронта пожара и отталкивание от препятствий и соседних аппаратов. Распределенный протокол согласования стабилизирует полет на общей опорной высоте, что гарантирует сопоставимые углы обзора. Для оптимального распределения вдоль линии фронта используется модифицированный алгоритм роя частиц (Particle Swarm Optimization, PSO), позволяющий снизить конкуренцию между дронами и уменьшить лишние манёвры. Проведена серия вычислительных экспериментов, в которых сопоставлены классический APF и гибрид APF+PSO для решения задачи оптимизации функционала эффективности движения роя БПЛА. Гибридная схема APF+PSO снижает значение функционала эффективности почти на порядок по сравнению с классическим методом APF; уменьшает вариативность поведения роя; поддерживает согласованную высоту без выраженного перерегулирования и обеспечивает корректный обход препятствий при движущемся фронте. Минимальные междроновые дистанции не опускались ниже порогового значения 5 м, что подтверждает соблюдение требований безопасности. Алгоритм демонстрирует устойчивое слежение за движущимся фронтом на протяжении всего горизонта моделирования, обеспечивая корректный обход препятствий. Разработанная стратегия сочетает вычислительную простоту с высокой надежностью. Дальнейшие исследования будут направлены на учет данных бортовых сенсоров (видео и тепловизоров), моделирование влияния ветра и рельефа, анализ задержек и потерь связи, а также расширение алгоритма на крупные группы БПЛА.

Ключевые слова: искусственные потенциальные поля, алгоритм роя частиц, распределенное управление, многоуровневая стратегия, навигация роя, оптимизация маршрутов, согласование высот, гибридные алгоритмы.

1. Введение. Масштабные ландшафтные пожары остаются одной из наиболее труднопредсказуемых и быстро эволюционирующих угроз для экосистем, инфраструктуры и населения, и потому требуют непрерывного наблюдения за фронтом распространения огня в реальном времени [1]. Критические решения (куда направить наземные бригады, какой очаг возгорания тушить

в первую очередь, как эвакуировать людей) принимаются на основе информации о текущем положении и скорости продвижения линии огня. На форму и направление фронта пожара каждую минуту влияют ветер, влажность, рельеф и наличие горючего материала. Спутниковая съёмка даёт снимки лишь раз в несколько часов, а наземные посты наблюдения редко охватывают всю зону бедствия [2].

Использование роя беспилотных летательных аппаратов (БПЛА) частично решает проблему оперативного сбора данных. Дроны способны одновременно сканировать большую площадь, передавать термокадры в реальном времени и работать в труднодоступных или опасных районах. Но сама по себе группа дронов не гарантирует высокое качество наблюдений [3]. В условиях быстро меняющейся картины пожара фиксированное построение роя БПЛА быстро отстает от реального контура, индивидуальные реакции дронов приводят к распаду роя и к появлению незакрытых участков наблюдения. Передача каждому БПЛА полного глобального плана полёта в реальном времени практически невозможна, так как канал связи в зоне пожара перегружен, а вычислительные ресурсы бортовых контроллеров ограничены. Дополнительный риск создают манёвры в задымлённой среде. Растёт вероятность сближений между аппаратами и попадания в зоны повышенной температуры. Наконец, тепловизоры и видеокамеры имеют ограниченный угол поля зрения, поэтому для получения непрерывной мозаичной картины требуется удерживать почти одинаковую опорную высоту над рельефом местности, обеспечивая сопоставимые масштабы наблюдения для всех аппаратов.

Таким образом, возникает актуальная задача: на основе локальных измерений и обмена информацией с ближайшими соседями разработать распределённый алгоритм координации роя БПЛА, корректирующий траектории в реальном времени, удерживающий группу вдоль текущей линии фронта огня, выравнивающий высоту полёта и сохраняющий работоспособность при порывах ветра, появлении новых очагов и кратковременных потерях связи. При этом алгоритм должен укладываться в доступные ресурсы сети и бортовых вычислений.

2. Обзор тематических научных работ. БПЛА стали неотъемлемым инструментом для раннего обнаружения и реагирования на лесные пожары, поскольку обеспечивают сбор данных в режиме реального времени, что является критически важным фактором для действий при ЧС [4]. Особое внимание уделяется повышению эффективности обнаружения и оценке динамики пожара средствами одиночных и групповых платформ [5, 6]. Данные

наблюдений служат основой оперативных решений (распределения наземных сил, выбора приоритетных участков тушения и организации эвакуации), поэтому требуется практически непрерывное покрытие динамически изменяющегося фронта огня.

Для существующей проблемы предложены как алгоритмические, так и организационно-технические решения. Показана стратегия совместных действий нескольких роев БПЛА на основе улучшенного оптимизационного алгоритма, обеспечивающая согласование задач и маршрутов в меняющейся обстановке [7]. Описаны системы мониторинга с применением БПЛА: архитектура, типовые полезные нагрузки, каналы передачи данных, особенности развёртывания и ограничения реального применения, а также практические рекомендации по организации наблюдений [8]. Представлены классификации платформ и оценка их пригодности для мониторинга [9].

Современные методы отмечают смещение акцента к распределённым подходам и алгоритмам, способным адаптироваться к быстро меняющейся обстановке на фронте пожара. В частности, онлайневые и гибридные методы оценки фронта пожара используются вместе с вероятностными и эвристическими планировщиками маршрутов, что позволяет строить траектории с учётом ограничений сети и вычислительных ресурсов, например, при планировании маршрутов в средах с ненадежной связью [10].

В работе [11] предложена совместная схема распределения задач и маршрутизации группы БПЛА в динамичной обстановке на рельефной местности. Траектории планируются по многокритериальному функционалу, учитывающему время, покрытие/угол обзора, перепады высоты и погодные риски при ограничениях связи. При этом не всегда вводится явный механизм распределённого согласования параметров полёта между аппаратами, например, выравнивание высоты или углов обзора камер.

Наряду с глобальной оптимизацией маршрута и локальными обходами препятствий важна устойчивость построения группы. Необходимо предотвращать «развал» роя при внешних воздействиях (ветровые порывы, новые очаги пожара, кратковременная потеря связи), а также поддерживать общую высоту полёта и связность сети. Современные работы предлагают распределённые законы взаимодействия между соседями и схемы формирования роя, позволяющие при внешних возмущениях сохранять связность группового графа и возможность агентам перестраиваться в рое в отсутствие глобального централизованного координатора [12].

В задачах распределённого управления роем широко используются методы согласования состояний (положение, скорость, высота) на основе локального обмена данными. В работе [13] предложена многоуровневая архитектура распределённого согласования для крупного роя: иерархический граф взаимодействий (уровни подграфов) сохраняет связность и надёжность при росте числа БПЛА. В каждом уровне применяются потенциальные функции для формирования целевой конфигурации и предотвращения столкновений; далее реализуется выравнивание курсов за счёт обмена информацией внутри и между уровнями, что ускоряет унификацию направлений движения.

Эвристические алгоритмы, такие как генетический (Genetic Algorithms, GA), муравьиный (Ant Colony Optimization, ACO), эволюционные (Differential Evolution, DE; Covariance Matrix Adaptation Evolution Strategy, CMA-ES) активно применяются в планировании траекторий БПЛА, поскольку позволяют оптимизировать сложные нелинейные функционалы [14, 15].

Генетические алгоритмы особенно эффективны в дискретных комбинаторных задачах маршрутизации и распределения заданий и требуют на каждом шаге операции «отбор, скрещивание, мутации» часто с процедурами восстановления допустимости решений при нарушении ограничений [14].

Муравьиные алгоритмы ориентированы на графовые дискретные постановки и поддерживают феромонные структуры [14], обновление которых создаёт вычислительные и коммуникационные расходы и инерцию из-за испарения, что нежелательно при быстро меняющейся линии фронта пожара и локальном обмене в рое.

Непрерывные эволюционные методы (DE, CMA-ES) успешно применяются в планировании [10], но требуют многократных оценок целевой функции (DE) или работы с ковариационной матрицей размерности $D \times D$ (CMA-ES), что повышает ресурсоёмкость работы на борту БПЛА в режиме онлайн.

На основе метода оптимизации роя частиц (Particle Swarm Optimization, PSO) [16] в работе [17] предложен улучшенный метод LGPSO (Lévy-Greedy PSO), в котором к классическому PSO добавлены случайные шаги для выхода из локальных минимумов (полёты Леви) и правило принятия шага с использованием «жадного» алгоритма. В трёхмерных сценариях это приводит к более гладким траекториям с умеренными наборами высоты, снижению энергозатрат и повышению устойчивости полёта [18].

Одним из широко применяемых подходов для локальной навигации и устойчивого обхода препятствий являются методы искусственных потенциальных полей (Artificial Potential Field, APF) [19]. Однако классическая постановка метода APF имеет ряд ограничений: склонность к попаданию в локальные минимумы потенциального поля, возникновение нежелательных колебаний и избыточной извилистости траектории, а также риск недостижимости цели при сложной конфигурации препятствий [20].

Работа [21] рассматривает комбинацию улучшенного искусственного потенциального поля (IAPF) с протоколом согласования. Предложенный алгоритм нацелен на формирование и восстановление ожидаемого построения после обхода препятствий с достижением согласования по относительному положению, высоте и скорости БПЛА. Каждый аппарат корректирует курс и удерживает заданную геометрию строя с учётом избегания столкновений и следования траектории. Показаны устойчивость и масштабируемость построения, а также сглаженные колебания курса БПЛА при моделировании [22 – 24].

Таким образом, существующие подходы показывают, что PSO-алгоритмы эффективны для планирования многоцелевых маршрутов БПЛА с учетом безопасности и экономии энергии [17]; являются практическим компромиссом для бортового применения; соответствуют непрерывной постановке; устойчивы к негладкости и многокритериальности; их реализация не требует тяжёлых популяционных структур [10, 13, 14, 16]. Методы согласования состояний вместе с искусственными потенциальными полями обеспечивают безопасное сплошное движение дронов с быстрым восстановлением построения [23]; многоуровневое согласование гарантирует масштабируемость и устойчивость при большом количестве БПЛА [24]. В нашей работе мы интегрируем эти идеи для решения задачи слежения за фронтом пожара, где поддерживается коллективное равновесие роя БПЛА по опорной высоте и оптимизируются траектории полета по многоцелевому критерию.

3. Математическая модель управления роем БПЛА. В бортовой практике применяется иерархическая структура управления летательными аппаратами [1, 2, 10]: внутренний (быстрый) уровень стабилизирует ориентацию и реализует заданные линейные/угловые ускорения аппарата, а внешний (медленный) уровень решает задачи навигации (ведёт положение/скорость, формирует опорные воздействия и распределяет аппараты по цели).

Сделаем ряд допущений.

1. Внутренний уровень управления БПЛА с помощью автопилота быстро стабилизирует ориентацию и обеспечивает соблюдение ограничений по ускорениям.

2. Внешний уровень действует на существенно более медленных временных масштабах и задаёт опорные воздействия для движения. При этом характерные скорости и углы крена/тангла остаются умеренными.

3. БПЛА представляется геометрической точкой с массой без собственных размеров и без явной вращательной динамики.

Введенных допущений достаточно, чтобы в качестве математической модели, описывающей динамику и управление полётом БПЛА, рассматривать упрощенную точечную кинематическую модель внешнего уровня без потери адекватности на горизонте планирования [1, 2, 10].

Для каждого дрона i , $i = \overline{1, N}$ введём состояние, $\mathbf{x}_i = (x_i, y_i, h_i)$, где (x_i, y_i) – горизонтальная позиция, h_i – высота над землей. Заметим, что вектор состояния и управляющие воздействия являются функциями времени t . Зависимость от времени для краткости записи опускается, если это не имеет принципиального значения для изложения.

Высота h_i поддерживается отдельно по распределённому закону согласования, управляющее действие напрямую задаёт ускорение аппарата, а горизонтальное положение получается двойным интегрированием ускорения по времени

$$\ddot{\mathbf{p}}_i = \mathbf{u}_i + \mathbf{F}_i, \quad (1)$$

где $\mathbf{p}_i = (x_i, y_i)$ – горизонтальная координата i -го дрона, \mathbf{u}_i – вектор управляющего ускорения (внешний планировщик), а \mathbf{F}_i – вектор результирующих сил от искусственных потенциалов (притяжение к фронту пожара, отталкивание от препятствий и от других дронов).

Для эффективного уклонения от препятствий при формировании траектории \mathbf{x} применим метод APF [25]. Суммарная сила \mathbf{F}_i на БПЛА складывается из составляющих:

$$\mathbf{F}_i = \mathbf{F}_{i,L} + \sum_{o \in \text{Obst}} \mathbf{F}_{i,o} + \sum_{i \neq j} \mathbf{F}_{i,j}, \quad (2)$$

где $\mathbf{F}_{i,L}$ – притягивающая сила к цели (линия фронта пожара), $\mathbf{F}_{i,o}$ – отталкивающая сила от каждого препятствия o из множества препятствий $Obst$, $\mathbf{F}_{i,j}$ – потенциал от другого БПЛА j , обеспечивающий предотвращение столкновений и моделирующий коммуникационный вес.

Опишем каждую результирующую силу в формуле (2).

Притяжение к фронту пожара. Целевая конфигурация – это согласованная линия из БПЛА, следующая за линией фронта пожара.

Фронт в общем случае представляет собой непрерывную кривую на местности, изменяющуюся во времени с ограниченной скоростью без скачков и разрывов. Для оперативного задания фронта будем использовать его дискретное представление в виде набора опорных (реперных) точек \mathbf{s}_L , извлекаемых из термо- и мультиспектральных спутниковых данных и постоянно обновляемых по мере поступления новых наблюдений [1 – 3, 23]. Эти точки упорядочим по длине дуги и по ним проведем кусочно-линейную аппроксимацию кривой линии фронта. В результате сформируем ориентированную ломаную $L(t)$, задающую согласованные касательные и нормали, используемые в законах управления.

В практике оперативного мониторинга пожаров и дистанционного зондирования с применением БПЛА ориентированная ломаная является стандартным форматом задания маршрута (набор точек и отрезков), совместимым с бортовыми планировщиками [10]. Адекватность кусочно-линейной аппроксимации обеспечивается при естественных для практики допущениях:

- 1) ограниченная кривизна линии фронта на рабочем горизонте (в местах высокой изломанности узлы уточняются);
- 2) частота обновления узлов ломаной выше характерной скорости деформации фронта, чтобы ошибка, обусловленная задержкой обновления, оставалась существенно меньше допустимой ширины зоны слежения;
- 3) шаг между соседними опорными точками согласован с пространственным разрешением исходных данных.

При улучшении качества и частоты наблюдений аппроксимация автоматически уточняется без изменения структуры управления. Для задач, требующих повышенной гладкости, ломаная может быть заменена сплайном без модификации принципов управления.

Чтобы рой БПЛА последовал за линией фронта пожара, введем притягивающий потенциал

$$U_{i,L}(\mathbf{p}_i) = \frac{1}{2} \alpha \|\mathbf{p}_i - \mathbf{s}_L\|^2, \quad (3)$$

где $\alpha > 0$ – коэффициент притяжения, регулирующий силу стремления к линии и обеспечивающий плавность подтягивания дронов к линии фронта без резких бросков.

В качестве управляющего воздействия на БПЛА рассмотрим антиградиент потенциала $U_{i,L}$:

$$\mathbf{F}_{i,L} = -\nabla_{\mathbf{p}_i} U_{i,L}.$$

Сила $\mathbf{F}_{i,L}$ направлена по нормали к ломаной $L(t)$, то есть перпендикулярно фронту, и линейно растёт с отклонением.

Отталкивание от препятствий. БПЛА должны удерживаться на безопасном расстоянии от неподвижных и подвижных препятствий (деревьев, столбов, горных выступов, а также опасных зон с высокой температурой или смога), которые представляются точкой \mathbf{p}_o и радиусом воздействия d_{safe} .

Пусть $d_{io} = \|\mathbf{p}_i - \mathbf{p}_o\|$ – расстояние от дрона i до объекта o . Для каждого препятствия o введем модель отталкивающего потенциала $U_{i,o}$: как только дрон вторгается в зону воздействия объекта o , то есть $d_{io} < d_{safe}$, запускается потенциал $U_{i,o}$ в виде квадратичной функции:

$$U_{i,o} = \begin{cases} \frac{1}{2} \beta \left(\frac{1}{d_{io}} - \frac{1}{d_{safe}} \right)^2, & d_{io} < d_{safe}, \\ 0, & d_{io} \geq d_{safe}; \end{cases}$$

где $\beta > 0$ – коэффициент отталкивания от препятствий, задающий жёсткость барьера.

Сила отталкивания, как антиградиент отталкивающего потенциала $U_{i,o}$, будет иметь вид:

$$\mathbf{F}_{i,o} = \begin{cases} -\nabla_{\mathbf{p}_i} U_{i,o}, & d_{io} < d_{safe}, \\ 0, & d_{io} \geq d_{safe}; \end{cases} = \begin{cases} \beta \left(\frac{1}{d_{io}} - \frac{1}{d_{safe}} \right) \frac{\mathbf{p}_i - \mathbf{p}_o}{d_{io}^3}, & d_{io} < d_{safe}, \\ 0, & d_{io} \geq d_{safe}. \end{cases}$$

Если дрон приближается к препятствию, то сила $\mathbf{F}_{i,o}$ растёт очень быстро и при этом удерживает аппарат за пределами опасной зоны.

Взаимодействие между БПЛА. Чтобы избежать столкновений и обеспечить согласованное движение, между дронами вводится дополнительный потенциал отталкивания по отношению к близким соседям

$$U_{i,j} = \begin{cases} \frac{1}{2} k_{ij} (\|\mathbf{p}_i - \mathbf{p}_j\| - d_{ij}^*)^2, & \|\mathbf{p}_i - \mathbf{p}_j\| < d_{ij}^*, \\ 0, & \text{иначе,} \end{cases}$$

где d_{ij}^* – минимальная дистанция между дронами, которую выбирают так, чтобы камеры не заслоняли друг друга и оставалось время на реакцию; k_{ij} – коэффициент отталкивания между агентами (чем k_{ij} больше, тем сильнее отталкиваются дроны). Сила $\mathbf{F}_{i,j}$ действует только при критическом сближении, а при угрозе столкновения быстро увеличивает дистанцию.

$$\mathbf{F}_{i,j} = \begin{cases} -\nabla_{\mathbf{p}_i} U_{i,j}, & d_{ij} < d_{ij}^*, \\ 0, & d_{ij} \geq d_{ij}^*; \end{cases} = \begin{cases} k_{ij} \frac{d_{ij}^* - d_{ij}}{d_{ij}} (\mathbf{p}_i - \mathbf{p}_j), & d_{ij} < d_{ij}^*, \\ 0, & d_{ij} \geq d_{ij}^*. \end{cases}$$

Отталкивающая сила симметрична относительно дрона j :
 $\mathbf{F}_{j,i} = -\mathbf{F}_{i,j}$.

Таким образом, сила отталкивания $\mathbf{F}_{i,j}$ обеспечивает нулевое взаимодействие на желаемом расстоянии и пропорциональное отталкивание при недопустимом сближении, предотвращая столкновения между дронами, но не распуская строй при допустимой дистанции.

Одновременно с силами горизонтального перемещения реализуется распределённый закон согласования высоты с опорой [26], обеспечивающий полёт всего роя на заданной опорной высоте h_{grid} в отсутствие централизованного координатора. Опорная высота h_{grid} задаётся регламентами связи/безопасности. Это означает, что для любого дрона i

$$\lim_{t \rightarrow \infty} (h_i(t) - h_{grid}) = 0, \quad (4)$$

тем самым разброс высот исчезает, и рой выстраивается на опорной высоте h_{grid} .

Для реализации требования (4) вводится распределённый динамический закон согласования высоты первого порядка с опорой

$$\dot{h}_i = -k_h \sum_{j \in N_i} (h_i - h_j) + k_{ref} (h_{grid} - h_i) \quad (5)$$

$k_h > 0$ – коэффициент согласования (чем значение больше, тем быстрее происходит выравнивание всех h_i); $k_{ref} > 0$ – коэффициент привязки к опорной высоте; N_i – множество соседей дрона i в графе связи.

В законе (5) первое слагаемое сглаживает отклонения относительно соседних дронов, второе обеспечивает приведение высоты к опорной высоте h_{grid} .

Все необходимые для безопасного и целесообразного перемещения требования уже заложены в структуру потенциалов (2): притягивающий член формирует «потенциальный колодец» (локальный минимум) с дном на линии огня, так что градиент направляет траекторию БПЛА к этой линии, а барьерные члены обеспечивают избегание опасных зон и соблюдение минимальных дистанций. Если поверх этого поля вводить ещё один внешний планировщик u_i , возникает дублирование функций и регулятор должен уравновешивать собственные команды с теми же силами APF, от чего увеличивается вычислительная сложность и усложняется доказательство устойчивости. Поэтому примем инженерное решение отказаться от отдельного u_i и непосредственно использовать градиент

потенциального поля как команду. Формально это эквивалентно случаю, когда в уравнении (1) $\mathbf{u}_i \equiv 0$.

Таким образом, результирующая вертикально-горизонтальная схема управления роем БПЛА выглядит так:

$$\begin{cases} \ddot{\mathbf{p}}_i = \mathbf{F}_i, \\ \dot{h}_i = -k_h \sum_{j \in N_i} (h_i - h_j) + k_{ref} (h_{grid} - h_i) \end{cases} \quad (6)$$

Горизонтальный вектор \mathbf{F}_i непрерывно реагирует на движущийся фронт пожара $L(t)$, тогда как вертикальное согласование (5) гарантирует экспоненциальное выравнивание всех высот, не требуя внешнего лидера.

Принятая упрощённая модель (6) сочетает в себе вычислительную лёгкость и требуемые свойства безопасности: горизонтальный градиент APF реагирует на динамику фронта пожара и препятствия, тогда как протокол согласования стабилизирует высотное расположение роя.

4. Задача оптимизации маршрутов и управляющих воздействий на рой БПЛА. Задача для роя из N дронов заключается в том, чтобы непрерывно следовать вдоль линии фронта $L(t)$, сохраняя сеточную согласованную опорную высоту полёта h_{grid} и при этом минимизируя:

- угол обзора дрона для охвата наиболее широкой зоны фронта камерой;
- энергозатраты, зависящие от длины траектории и крутизны подъёмов;
- риск столкновения с препятствиями (деревья, рельеф, зоны сильного тепла) для поддержания безопасной дистанции.

Тогда целевую функцию, описывающую эффективность движения роя БПЛА, представим в виде

$$J = J_\theta + J_E + J_R , \quad (7)$$

где J_θ – угловой показатель, J_E – энергетический показатель, J_R – показатель риска столкновения с препятствиями.

На итоговый результат функционала (7) эффективности движения роя влияют значения, полученные от каждого дрона в рое, то есть

$$J(t) = \sum_{i=1}^N J_i(t), \quad (8)$$

$$J_i(t) = \omega_0 J_{\theta,i}(t) + \omega_E J_{E,i}(t) + \omega_R J_{R,i}(t), \quad (9)$$

где $J_i(t)$ – локальный вклад i -го дрона; коэффициенты $\omega_0, \omega_E, \omega_R > 0$ задают относительную важность широкого охвата, экономии батареи и безопасности соответственно [13].

Используя модель (6), зададим показатели (9) для локального вклада каждого дрона в функционал эффективности движения роя (8).

Угловой показатель. Пусть дрон летит на высоте h_i и должен контролировать отрезок линии фронта длиной l_i (точки $\mathbf{s}_{L,i}$ – середины отрезков). Минимальный требуемый полуугол обзора $\theta_i = \arctg\left(\frac{l_i/2}{h_i}\right)$. Тогда угловой показатель для i -го дрона

$$J_{\theta,i} = \theta_i^2 = \arctg^2\left(\frac{l_i}{2h_i}\right).$$

Энергетический показатель. За один дискретный тик Δt горизонтальный пробег дрона равен $\|\mathbf{p}_i(t) - \mathbf{p}_i(t - \Delta t)\|$, вертикальный пробег $|h_i(t) - h_i(t - \Delta t)|$. Модель удельных затрат:

$$J_{E,i} = \|\mathbf{p}_i(t) - \mathbf{p}_i(t - \Delta t)\|^2 + \gamma_h |h_i(t) - h_i(t - \Delta t)|^2,$$

где $\gamma_h > 0$ – относительная «дороговизна» изменения высоты.

Показатель риска столкновения с препятствиями. Для каждого близкого препятствия o (дерево, скальный выступ, горячий очаг) и каждого близкого соседа j введем штраф

$$\phi_{obs}(d_{io}) = \beta \left(\frac{1}{d_{io}} - \frac{1}{d_{safe}} \right)^2, \quad \phi_{uav}(d_{ij}) = k_{ij}(d_{ij} - d_{ij}^*)_+^2,$$

где $x_+ = \max\{x, 0\}$. Тогда риски столкновения и термических зон:

$$J_{R,i} = \sum_{o \in O_i} \phi_{obs}(d_{io}) + \sum_{j \in N_i} \phi_{uav}(d_{ij}).$$

Таким образом, задача сводится к управлению системой дифференциальных уравнений (6), описывающих движение каждого БПЛА, при одновременном согласовании высот с целью минимизации функционала (7).

5. Применение метода PSO к задаче оптимизации маршрутов и управляющих воздействий. Введённый притягивающий потенциал (3) гарантирует, что каждый дрон быстро стремится к точке огневого фронта $L(t)$ в направлении, параллельном вектору нормали. Однако одного только нормального притяжения недостаточно, так как, если не добавить распределяющего механизма, дроны могут сконцентрироваться на одном участке линии, оставив другие сегменты без наблюдения, либо будет выстроена траектория, требующая лишних манёвров и расхода батареи.

Для равномерного и энергосберегающего распределения вдоль самой линии $L(t)$ добавим планировочный слой глобального поиска. В качестве такого слоя выберем поисковый слой алгоритма PSO [16], где каждому дрону сопоставим собственную «частицу», которая существует не в пространстве реальных координат \mathbf{p}_i , а в абстрактном пространстве желательных позиций \mathbf{s}_i . Алгоритм PSO будет оптимизировать расположение дронов по тангенциальному направлению относительно линии фронта $L(t)$.

Пусть для каждого момента времени t^k длина ломаной фронта параметризована абсциссой дуги $s \in [0, S(t^k)]$ и отображением $\mathbf{L}(s, t^k) = (x_L^k, y_L^k)$, где $S(t^k)$ – суммарная длина всей ломаной в момент t^k . Для каждого дрона i вводится скалярная виртуальная координата $s_i(t^k)$, определяющая положение закреплённой за ним точки на линии фронта. Текущая цель притягивающей силы формируется как $\mathbf{s}_i(t^k) = \mathbf{L}(s_i(t^k))$; именно к этой точке направлен

градиент $-\frac{1}{2}\alpha\|\mathbf{p}_i - \mathbf{s}_i\|^2$ в формуле (3) для притягивающего потенциала. Из-за того, что \mathbf{s}_i всегда принадлежит $L(t)$, нормаль к фронту сохраняется, а сам фронт остаётся единственной несущей линией, на которой располагается рой.

Чтобы уменьшить вычислительную нагрузку, будем применять однопараметрическую версию алгоритма PSO, где состояние частицы ограничивается одной скалярной величиной $s_i(t^k)$. При этом все атрибуты метода PSO (поисковая скорость, личная память и глобальная память) остаются, но каждый дрон-частица будет хранить и обновлять только свои.

В начале шага t^k частица i оценивает свой локальный вклад J_i , при этом каждая компонента в целевой функции (8) берёт в расчёт лишь величины, относящиеся к самой частице и ее ближайшим соседям. Вычисление не требует полной карты положения всего роя и поэтому легко выполняется на борту.

Сравнив J_i с хранящимся в памяти значением, частица обновляет свою личную лучшую абсциссу P_i , если новый результат оказался лучше. После обмена сообщениями между ближайшими частицами определяется глобальный победитель: G будет равен тому $s_i(t^k)$, $i = \overline{1, N}$, при котором достигается минимальный из всех локальных показателей. Далее применяется классическое правило изменения поисковой скорости и позиции метода PSO на m -ой итерации [16]:

$$w_i^m = \omega w_i^{m-1} + c_1 r_1 (P_i - s_i^{m-1}) + c_2 r_2 (G - s_i^{m-1}),$$

$$s_i^m = s_i^{m-1} + w_i^m;$$

где P_i – лучшая позиция i -ой частицы (личный опыт); G – лучшая позиция всего роя частиц (глобальный опыт); ω – коэффициент инерции скорости; c_1, c_2 – коэффициенты, определяющие влияние личного и коллективного опыта; r_1, r_2 – случайные числа из промежутка $[0, 1]$. В случае выхода $s_i(t^k)$ за пределы промежутка

$[0, S(t^k)]$ необходимо отразить виртуальную точку $s_i(t^k)$ от концов промежутка.

Описанная процедура выполняется несколько раз подряд (три-пять микрошагов) прежде чем перейти к расчёту сил искусственного поля. Этого достаточно, так как фронт между двумя последовательными глобальными шагами меняется незначительно, а личная и глобальная памяти частиц уже содержат стабилизированные приближения. Полученный набор $s_i(t^k)$ передаётся силовому слою, где формируется притягивающий градиент, дополняемый потенциалами отталкивания от препятствий при малых междроновых дистанциях. Модель (6) перемещает аппарат ближе к новой цели, после чего весь цикл повторяется.

Для поиска оптимальной расстановки беспилотников вдоль движущегося фронта пожара $L(t)$ применяется двухуровневая схема управления. Первый поисковый уровень заключается в том, что на каждом дискретном временном шаге t_k внешние датчики обновляют геометрию линии $L(t_k)$, протокол согласования (5) корректирует высоты, а роевый планировщик (метод PSO) сдвигает параметры $s_i(t^k)$, тем самым задавая новые точки s_i . Второй силовой уровень (метод APF), описанный механической моделью (6), пересчитывает градиенты потенциалов и задаёт ускорения двойного интегратора, которые плавно подтягивают реальные координаты \mathbf{p}_i к «желательным» точкам s_i на фронте.

Таким образом, метод PSO отвечает за глобальный, пусть даже идеалистический, поиск конфигурации, а метод APF превращает этот поиск в физически осуществимую и безопасную траекторию.

6. Гибридный алгоритм APF+PSO.

Этап 1. Инициализация ($t = 0$). Подготовка перед стартом миссии.

1. Получить исходную ломаную фронт $L(0)$ и её длину дуги $S(0)$, задать опорную высоту h_{grid} .

2. Для каждого дрона i , $i = \overline{1, N}$ выбрать начальную абсциссу $s_i(0) = \frac{i-1}{N-1} S(0)$ (базовое равномерное распределение).

3. Для метода PSO задать поисковые параметры:

$$w_i(0) = 0, \quad P_i = s_i(0), \quad J(P_i) = +\infty.$$

4. Задать константы APF и согласования $\alpha, \beta, \gamma, k_h$ и параметры PSO ω, c_1, c_2 .

5. Зафиксировать дискретный шаг времени Δt и число микрошагов M для метода PSO за такт.

Этап 2. Основной цикл по дискретному времени $t_k = k \Delta t$.

1. Актуализация среды: от внешних сенсоров получить новую ломаную $L(t_k)$ и список препятствий $O(t_k)$; одновременно фиксировать длину дуги $S(t_k)$.

2. Обмен высотами и согласование:

$$h_i(t_k) = h_i(t_{k-1}) - k_h \Delta t \sum_{j \in N_i(t_k)} (h_i(t_{k-1}) - h_j(t_{k-1})) + k_{ref} \Delta t (h_{grid} - h_i(t_{k-1})).$$

3. Внутренний поисковый цикл PSO (для $m = \overline{1, M}$).

a. для каждого дрона вычислить локальный вклад $J_i^m(t_k)$ в целевую функцию (8);

б. обновить личную память: если $J_i^m(t_k) < J(P_i)$, то

$$P_i = s_i^{m-1}(t_k), \quad J(P_i) = J_i^m(t_k);$$

в. обновить глобальную память: если $G(t_k) = \arg \min_i J(P_i)$, то

$$P_i = s_i^{m-1}(t_k), \quad J(P_i) = J_i^m(t_k);$$

г. для каждой частицы обновить ее скорость и положение:

$$w_i^m(t_k) = \omega w_i^{m-1}(t_k) + c_1 r_1 (P_i - s_i^{m-1}(t_k)) + c_2 r_2 (G(t_k) - s_i^{m-1}(t_k)),$$

$$s_i^m(t_k) = s_i^{m-1}(t_k) + w_i^m(t_k);$$

д. если после обновления скорости частица выходит за допустимый диапазон $[0, S(t^k)]$, то отразить частицу:

$$s_i^m(t_k) = \begin{cases} -s_i^m(t_k), & s_i^m(t_k) < 0, \\ 2S(t^k) - s_i^m(t_k), & s_i^m(t_k) > S(t^k); \end{cases}$$

- е. по завершении внутреннего поискового цикла:

$$s_i(t_k) = s_i^M(t_k), w_i(t_k) = w_i^M(t_k).$$

4. Вычислить силы APF:

- а. точка цели $s_i(t_k) = \mathbf{L}(s_i(t_k), t_k)$;
 б. сила притяжения к линии фронта:

$$\mathbf{F}_{i,L}(t_k) = -\alpha(\mathbf{p}_i(t_{k-1}) - \mathbf{s}_i(t_{k-1}));$$

- в. силы отталкивания от препятствий:

$$\mathbf{F}_{i,o}(t_k) = -\sum_{o \in O_i(t_k)} \nabla_{\mathbf{p}_i} U_{i,o};$$

- г. силы междронового взаимодействия:

$$\mathbf{F}_{i,j}(t_k) = -\sum_{i \neq j} \nabla_{\mathbf{p}_i} U_{i,j};$$

- д. суммарные силы:

$$\mathbf{F}_i(t_k) = \mathbf{F}_{i,L}(t_k) + \mathbf{F}_{i,o}(t_k) + \mathbf{F}_{i,j}(t_k).$$

5. Обновить координаты роя дронов. Проинтегрировать на интервале Δt дифференциальное уравнение $\ddot{\mathbf{p}}_i = \mathbf{F}_i(t_k)$ и получить $\mathbf{p}_i(t_k), \dot{\mathbf{p}}(t_k)$.

Этап 3. Завершение. Повторить шаги 1 – 5 этапа 2 для $k = 1, \dots, \lfloor T / \Delta t \rfloor$. В результате будут получены траектории $\mathbf{p}_i(t_k), h_i(t_k)$ всех БПЛА, обеспечивающие минимизацию функционала эффективности движения $J(t_k) < \sum_i J_i^M(t_k)$ при сохранении безопасности и согласованной высоты полёта.

7. Вычислительный эксперимент. Для проверки работоспособности предложенной архитектуры управления и количественной оценки её характеристик была проведена серия из 50 вычислительных экспериментов. В рамках компьютерных симуляций

моделировалось кооперативное сопровождение роем из N БПЛА за движущимся криволинейным фронтом пожара с учётом препятствий и ограничений на междроновые расстояния.

Численные эксперименты выполнены в среде Python 3.11 с использованием библиотек NumPy 1.26 и Matplotlib 3.8. Вычисления проведены на ноутбуке с процессором Intel Core i7-11800H и 16 Гбайт оперативной памяти.

Приведем параметры модели и алгоритма.

Размер роя. В работах [1 – 3, 10, 23] по мониторингу лесных пожаров отмечается, что в реальной эксплуатации применяются небольшие группы БПЛА из-за ограничений канала связи (полоса, помехи, задымление), требований к надзору операторов и бортовых вычислительных ресурсов. Поэтому рассматривается рой из $N = 6$ дронов.

Характеристики фронта пожара и временной горизонт. Для имитации динамики пожара вводится продольный дрейф фронта огня вдоль оси X :

$$y(x, t) = 30 + 10 \sin(0,05(x - v_{front}t) + 0,1t).$$

Каждое положение точки фронта со временем смещается на $\Delta x = v_{front}t$ в горизонтальном направлении, скорость дрейфа постоянна $v_{front} = 0,5$ (м/с). Такой тип движения фронта моделирует его продольное распространение по местности, например, под действием ветрового переноса или особенностей рельефа.

Выбранная синусоидально дрейфующая кривая – это минимальная воспроизводимая модель нестационарного фронта со строго ограниченными наклоном, кривизной и скоростью изменений. Она достаточна, чтобы надёжно проверить устойчивость и поведение алгоритма сопровождения роем.

Пространственная длина волны фронта $\lambda = 2\pi / 0,05 \approx 126$ (м). При фиксированном x фаза $\theta(x, t) = 0,05(x - v_{front}t) + 0,1t$ меняется во времени с угловой частотой

$$\omega_t = \partial\theta / \partial t = 0,1 - 0,05v_{front} = 0,075 \text{ (рад/с)},$$

что соответствует периоду $T_t = 2\pi / \omega_t \approx 84$ (с). Поэтому выберем горизонт моделирования T 30-100 с, так как он захватывает разгон и

как минимум один установившийся цикл деформаций (≈ 84 с), что достаточно для оценки устойчивости и режимов сопровождения.

Шаг интегрирования $\Delta t = 0,1$ (с) = 10 (Гц) – типичная частота внешнего контура автопилота.

Параметры APF. Коэффициент притяжения к фронту $\alpha = 0,2$.

При $\Delta t = 0,1$ (с) эффективный дискретный шаг притяжения $\alpha \Delta t = 0,2 \cdot 0,1 = 0,02$ (2 % ошибки за такт), что даёт характерное время затухания порядка нескольких секунд и исключает перерегулирование при типичных скоростях роя.

Согласно нормативу международной организации гражданской авиации (ICAO) [27] минимальное междроновое расстояние $d^* = 5$ (м) и радиус воздействия между дроном и препятствием $d_{safe} = 5$ (м). Таким образом, 5 м – минимально допустимый интервал между аппаратами и минимальная дистанция до опасного объекта.

Коэффициент отталкивания от препятствий $\beta = 100$; коэффициент отталкивания между дронами $k_{ij} = 50$. Параметры выбраны так, чтобы при приближении к порогу 5 м отталкивающий «ускоряющий» градиент был соизмерим с реализуемыми внешним контуром ускорениями (порядка $1\text{м}/\text{с}^2$), а при более опасном сближении (3 м) – возрастал до $3\text{--}4\text{м}/\text{с}^2$ и срабатывал до входа в запретную зону.

Препятствия и опасные зоны. Сгенерированы $O = 10$ точечных объектов (отдельные деревья, скальные выступы, горячие очаги), абсциссы которых распределены равномерно вдоль рассматриваемого участка фронта, ординаты – по закону нормального распределения. Радиусы опасных зон вокруг препятствий считаются незначительными по сравнению с d_{safe} , то есть дрон реагирует на препятствие только войдя в зону 5 м вокруг него.

Параметры PSO. Количество микрошагов $M = 5$. Чтобы сохранить инерцию вдоль движущегося фронта примем $\omega = 1$, равные веса «личной» и «глобальной/социальной» памяти $c_1 = c_2 = 1,7$ исключают систематический дрейф к одному из полюсов (индивидуальная память против общего лучшего), что важно при равномерном покрытии фронта.

Алгоритм согласования высоты. Опорная высота $h_{grid} = 100$ (м) соответствует оптимальной высоте обзора при мониторинге пожара и находится в безопасном диапазоне по отношению к очагам огня [27]; коэффициент согласования $k_h = 0,1$ и коэффициент привязки к опорной высоте $k_{ref} = 0,05$ выбраны так, чтобы обеспечивались устойчивость, отсутствие колебаний и достижение требуемой точности по опорной высоте за $\sim 8\text{--}10$ с. Связность графа обмена по высоте поддерживается либо через пороговую дальность (соседями считаются дроны в радиусе 30 м), либо с помощью случайного графа с вероятностью наличия каждого ребра около 0,5.

Начальные условия. Исходные позиции дронов выбираются поблизости от фронта пожара. Дроны стартуют на небольшом фиксированном нормальном расстоянии позади линии огня (около 10 м позади фронта, что обеспечивает изначально безопасное удаление) и с равномерным распределением вдоль участка фронта. Начальные высоты дронов заданы с разбросом около опорной высоты h_{grid} .

Эксперимент 1. Сравнение значений функционала эффективности движения (7) методами APF и APF+PSO.

Сравниваются два подхода горизонтального управления роем: классический «реактивный» контур на основе искусственных потенциалов (APF) и гибридный контур (APF+PSO). Оба контура работают в идентичных условиях. На каждом такте моделирования для обеих групп вычисляется текущее значение функционала эффективности движения роя $J(t)$, определяемого формулой (7).

Для наглядности изменения функционала $J(t)$ показаны в логарифмической шкале по оси ординат (рисунок 1). Серия из 50 симуляций подтвердила статистическую устойчивость результатов. Для гибридного алгоритма APF+PSO значения функционала в среднем находятся в пределах порядка $10^3\text{--}10^4$, тогда как для классического APF аналогичные значения вычисляются на уровне $10^4\text{--}10^5$. Таким образом, переход от APF к APF+PSO приводит к уменьшению значений функционала $J(t)$ почти на один порядок.

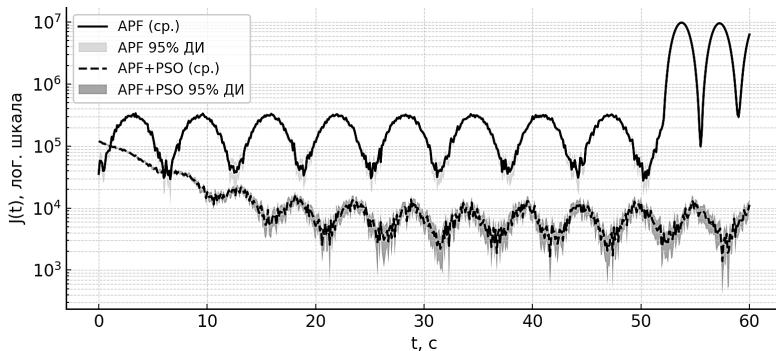


Рис. 1. Значения функционала эффективности движения роя $J(t)$
для различных алгоритмов

Для обоих алгоритмов наблюдаются колебания значений функционала $J(t)$ (рисунок 1), однако их размеры и характер различны. Для APF величина отклонений колебаний достигает 20–25% от среднего значения функционала. Это связано с тем, что алгоритм использует только локальные градиенты искусственных потенциалов. Каждый дрон реагирует на ближайшее окружение, и это приводит к конкуренции за соответствующие участки фронта и образованию выраженных разностных режимов. В случае APF+PSO колебания также присутствуют, но их величина значительно ниже (8–12%). Подобный эффект обусловлен итеративной процедурой оптимизации методом PSO. Обновления позиций частиц происходят порциями и со случайными параметрами, поэтому появляются небольшие колебания, но они подавляются настройками алгоритма и притяжением сил APF к линии фронта. В результате значение функционала для APF+PSO меньше, чем у APF, и на качество движения роя это заметно не влияет.

Таким образом, эксперимент 1 показывает, что гибридный алгоритм APF+PSO не только уменьшает значения функционала эффективности движения роя, но и уменьшает амплитуду колебаний более чем в два раза, что обеспечивает устойчивое поведение роя во всех 50 прогонах симуляции.

Эксперимент 2. Согласование высот с опорной высотой.

Проверяется согласованность полёта роя на опорной высоте $h_{grid} = 100(\text{м})$, и оценивается скорость выравнивания. Для того, чтобы считать фронт неподвижным, рассматривается короткий горизонт $T = 10(\text{с})$. Граф связности по высоте – случайный неориентированный

(вероятность ребра $\approx 0,5$). Начальные высоты намеренно различны (диапазон порядка десятков метров относительно h_{grid}). Связь разреженная $k_{ref} = 0,05$.

Для количественной оценки качества согласования высот используется метрика средних модульных отклонений высот от опорной высоты:

$$e_h(t) = \frac{1}{N} \sum_{i=1}^N |h_i(t) - h_{grid}|.$$

Полученные кривые (рисунок 2) демонстрируют экспоненциальное затухание ошибки $e_h(t)$. К 8–10-й секунде все прогоны входят в полосу $\pm 0,5$ м и далее в ней удерживаются. Перерегулирования не зафиксировано, так как после первого входа в допуск $\pm 0,5$ м повторных выходов за пределы полосы не наблюдалось ни в одном запуске. Монотонность $e_h(t)$ и сужающийся 95% доверительный интервал (ДИ) показывают, что ни средняя траектория, ни подавляющее большинство реализаций не демонстрируют таких «выбросов». Такая «спокойная» динамика обеспечивает стабильные углы обзора камер дронов в рое и сопоставимость масштабов наблюдений.

Таким образом, даже при разреженной связи и умеренном коэффициенте согласования $k_h = 0,1$ алгоритм APF+PSO обеспечивает быстрый и гладкий выход роя на заданный опорный уровень.

Эксперимент 3. Сопровождение дрейфующего фронта.

Проверяется способность алгоритма APF+PSO удерживать рой на движущемся фронте пожара в течение длительного времени $T = 40$ (с). В окружении присутствуют 10 случайно сгенерированных препятствий.

Для фиксации эволюции системы взаимодействия роя с линией фронта огня для одного из прогонов показана последовательность моментальных кадров положения роя через равные интервалы времени (рисунок 3). Девять кадров снимаются каждые 5 с, образуя покадровый коллаж движения роя вдоль фронта. На каждом кадре отображается текущая линия фронта, дроны помечены маркерами разной формы, препятствия обозначены в виде малых черных точек.

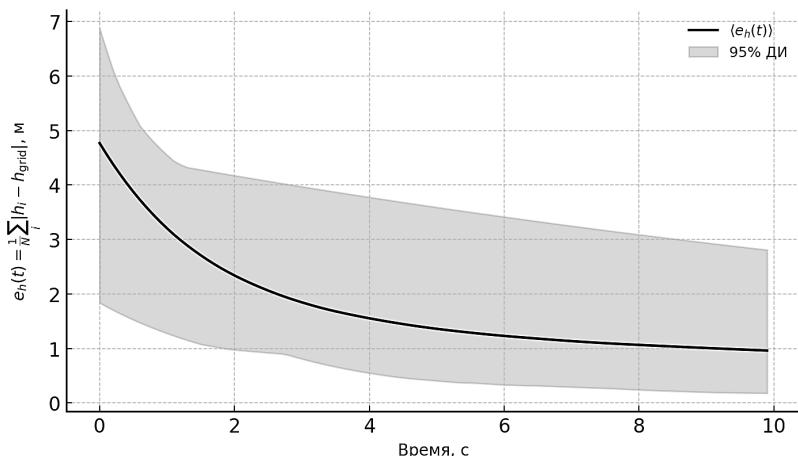


Рис. 2. Динамика средней ошибки по высоте

На основании покадровой визуализации (рисунок 3) можно заключить, что рой успешно сопровождает движущийся фронт пожара на всём промежутке времени. Дроны устойчиво держатся возле локального профиля линии огня, невзирая на её движение. Скоплений нескольких БПЛА в одной точке фронта не возникает.

Количественная проверка выполнена по временными траекториям минимальных дистанций «БПЛА–БПЛА» и «БПЛА–препятствие», усреднённых по сериям прогонов с построением 95%-го доверительного интервала (рисунок 4).

Средняя кривая «минимальная дистанция БПЛА–БПЛА» менее чем за 5 с выходит к уровню 5,25–6 м и держится в допустимом коридоре; её 95%-й интервал остаётся целиком выше порога безопасности 5 м. Такая конфигурация поддерживается тем, что в модель включено жёсткое условие на безопасность: после каждого шага интегрирования все пары «БПЛА–БПЛА» и «БПЛА–препятствие» итеративно разводятся минимум до 5,25 м. Таким образом, обеспечивается гарантированный запас $\approx 0,25$ м даже при дискретизации по времени, и нижняя граница 95%-го интервала не пересекает порог безопасности 5 м.

Медианная кривая «БПЛА–препятствие» располагается выше кривой «БПЛА–БПЛА» и сопровождается более широким доверительным интервалом. Это объясняется тем, что часть препятствий располагается существенно дальше активной зоны полёта, и потому минимальная дальность до ближайшего из них

заметно варьирует и часто значительно превосходит порог 5 м. При этом 95%-й коридор сужается по мере стабилизации построения, а его нижняя граница сохраняет положительный запас над минимальным безопасным расстоянием 5 м, что подтверждает корректный обход препятствий силами APF при дополнительной защите за счёт указанного жёсткого условия.

Предложенный алгоритм APF+PSO позволяет рою длительно сопровождать дрейфующий фронт пожара, не нарушая при этом требований локальной безопасности.

Результаты экспериментов показывают, что гибридная схема APF+PSO при выбранных настройках уверенно решает задачу сопровождения динамического фронта с соблюдением ограничений безопасности и согласованием по высоте. Алгоритм остаётся вычислительно лёгким и пригодным для последующей интеграции в бортовые реализации.

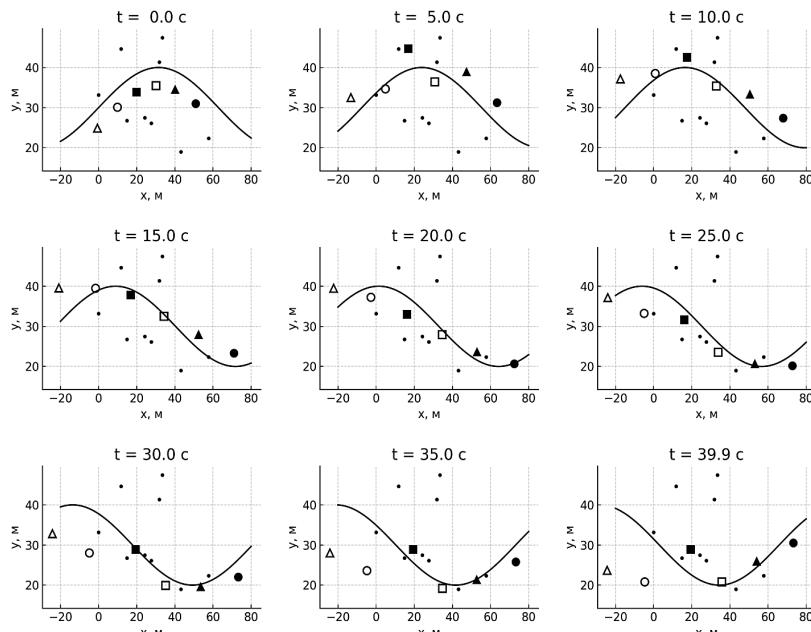


Рис. 3. Покадровое сопровождение роем БПЛА дрейфующего фронта пожара

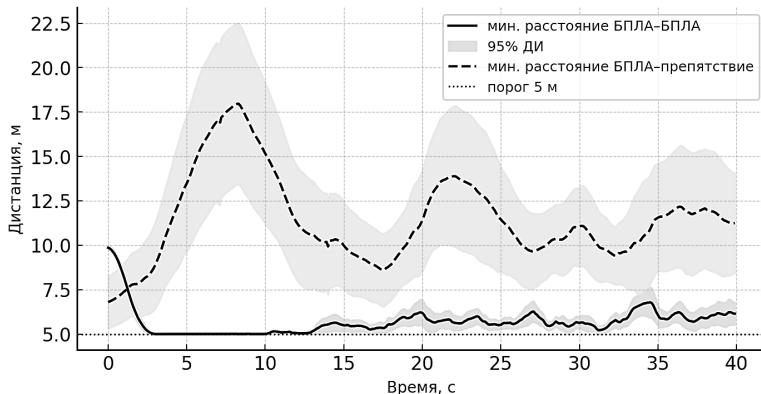


Рис. 4. Временные траектории минимальных дистанций

8. Заключение. В работе предложена и обоснована гибридная архитектура координации роя БПЛА для сопровождения динамического фронта лесного пожара, сочетающая три взаимодополняющих механизма: горизонтальное управление на основе метода искусственных потенциальных полей (APF), при котором результирующая сила формируется как суперпозиция сил притяжения к линии огня $L(t)$, междронового и препятственного взаимодействия; распределённый закон согласования по опорной высоте, обеспечивающий экспоненциальное выравнивание высот h_i при связном графе связи; однопараметрическая модификация метода роя частиц (PSO) для оптимизации распределения БПЛА по длине дуги линии фронта. Предложенная архитектура позволяет одновременно удерживать дроны вблизи движущейся кромки огня при соблюдении безопасных дистанций (не менее 5 м) и обеспечивать равномерное распределение роя вдоль фронта, снижая избыточные манёвры и энергозатраты.

Серия из 50 вычислительных экспериментов показала, что дроны равномерно распределяются вдоль динамически изменяющейся линии огня $L(t)$; высоты h_i сходятся к опорной высоте h_{grid} , что подтверждает корректность выбранного закона согласования; значения функционала эффективности движения роя $J(t)$ для гибридного подхода APF+PSO заметно ниже, чем для классического APF. Важно, что требования безопасности обеспечиваются локальными барьерными функциями и не требуют централизованной системы контроля ограничений.

Проведённое исследование выполнено для роя из шести БПЛА. Алгоритм опирается на локальные взаимодействия между соседними дронами. При фиксированном числе соседей вычислительная и коммуникационная нагрузка на одного агента не растёт с увеличением количества дронов. Тем не менее поведение системы при росте численности роя зависит от связности графа, задержек и потерь в каналах, а также плотности препятствий. Поэтому масштабируемость на большие группы требует отдельной проверки.

Дальнейшее развитие исследований предусматривает переход от аналитически заданного описания фронта к его оценке по данным бортовых сенсоров (видео, тепловизоры) с моделированием влияния ветра и рельефа; учёт задержек и потерь в каналах связи при синтезе управления; масштабирование подхода на более крупные группы БПЛА.

Литература

1. Akhloifi M.A., Couturier A., Castro N.A. Unmanned Aerial Vehicles for Wildland Fires: Sensing, Perception, Cooperation and Assistance // *Drones*. 2021. vol. 5. no. 1.
2. Merino L., Caballero F., Martínez-de-Dios J.R., Maza I., Ollero A. An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement // *Journal of Intelligent & Robotic Systems*. 2012. vol. 65. no. 1. pp. 533–548.
3. Martínez-de-Dios J.R., Merino L., Caballero F., Ollero A. Automatic Forest-Fire Measuring Using Ground Stations and Unmanned Aerial Systems // *Sensors*. 2011. vol. 11. no. 6. pp. 6328–6353.
4. Косинов Д.Э. Обзор использования беспилотных летательных аппаратов при мониторинге лесных пожаров // Материалы Нац. науч.-практ. конф. «Циркулярная экономика для целей устойчивого развития отраслей и территорий». Воронеж: ВГЛТУ им. Г.Ф. Морозова, 2024. С. 193–198.
5. Zhu P., Song R., Zhang J., Xu Z., Gou Y., Sun Z., Shao Q. Multiple UAV Swarms Collaborative Firefighting Strategy Considering Forest Fire Spread and Resource Constraints // *Drones*. 2025. vol. 9. no. 1.
6. Liu Y., Chen C., Wang Y., Zhang T., Gong Y. A fast formation obstacle avoidance algorithm for clustered UAVs based on artificial potential field // *Aerospace Science and Technology*. 2024. vol. 147.
7. Wu R.-Y., Xie X.-C., Zheng Y.-J. Firefighting Drone Configuration and Scheduling for Wildfire Based on Loss Estimation and Minimization // *Drones*. 2024. vol. 8. no. 1. DOI: 10.3390/drones8010017.
8. Кузнецов А.В. Системы мониторинга лесных пожаров с использованием беспилотных летательных аппаратов // Пожарная и аварийная безопасность: материалы XVIII Междунар. конф. 2023. С. 622–626.
9. Серебряков А.Е., Гура Д.А., Дражецкий Д.А., Панченко Е.А. Типы БПЛА и возможности использования в целях мониторинга и предотвращения лесных пожаров // Наука. Техника. Технологии (Политехнический вестник). 2021. № 4. С. 175–178.
10. Debnath D., Vanegas F., Sandino J., Hawary A.F., Gonzalez F.A. A Review of UAV Path-Planning Algorithms and Obstacle Avoidance Methods for Remote Sensing Applications // *Remote Sensing*. 2024. vol. 16. no. 21.

11. Zhu P., Jiang S., Zhang J., Xu Z., Sun Z., Shao Q. Multi-Target Firefighting Task Planning Strategy for Multiple UAVs Under Dynamic Forest Fire Environment // Fire. 2025. vol. 8. no. 2.
12. Sun B., Gu Z., Xiong T. Event-Triggered Formation Tracking Control for Unmanned Aerial Vehicles Subjected to Deception Attacks // Electronics. 2021. vol. 10. no. 22.
13. Wang T., Zhao S., Xia Y., Pan Z., Tian H. Consensus Control of Large-Scale UAV Swarm Based on Multi-Layer Graph // Drones. 2024. vol. 6. no. 12. DOI: 10.3390/drones6120402.
14. Даринцев О.В., Мирганов А.Б. Аналитический обзор подходов к распределению задач в группах мобильных роботов на основе технологий мягких вычислений // Информатика и автоматизация. 2022. Т. 21. № 4. С. 729–757.
15. Смирнов А.В. Исследование влияния степени овражности целевой функции на погрешность определения координат ее минимума // Российский технологический журнал. 2023. Т. 11. № 6. С. 57–67.
16. Akimov A.A., Sapozhnikova K.A., Gnatenko Y.A. A Discrete Swarm Optimization Modification for the Multi Agent Traveling Salesman Problem // Proc. of the International Russian Smart Industry Conference (SmartIndustryCon). IEEE, 2025. pp. 418–424.
17. Cheng Q., Zhang Z., Du Y., Li Y. Research on Particle Swarm Optimization-Based UAV Path Planning Technology in Urban Airspace // Drones. 2024. vol. 8. no. 12.
18. Горшков И.Ф., Акимов А.А. Динамическая маршрутизация дронов для доставки заказов // Научно-технический вестник Поволжья. 2025. № 6. С. 202–205.
19. Rimon E., Koditschek D.E. Exact Robot Navigation Using Artificial Potential Functions // IEEE Transactions on Robotics and Automation. 1992. vol. 8. no. 5. pp. 501–518. DOI: 10.1109/70.163777.
20. Hao G., Lv Q., Huang Z., Zhao H., Chen W. UAV Path Planning Based on Improved Artificial Potential Field Method // Aerospace. 2023. vol. 10. no. 6.
21. Xiong H., Deng G., Liu Y., Wu W. Distributed event-triggered formation control of UGV-UAV heterogeneous multi-agent systems for ground-air cooperation // Chinese Journal of Aeronautics. 2024. vol. 37. no. 12. pp. 458–483.
22. Hartley J., Shum H., Ho S., Wang H., Ramamoorthy S. Formation control for UAVs using a Flux Guided approach // Expert Systems with Applications. 2022. vol. 205.
23. Partheepan S., Sanati F., Hassan J. Autonomous Unmanned Aerial Vehicles in Bushfire Management: Challenges and Opportunities // Drones. 2023. vol. 7. no. 1. DOI: 10.3390/drones7010047.
24. Shao R., Tao R., Liu Y., Yang Y., Li D., Chen J. UAV cooperative search in dynamic environment based on hybrid-layered APF // EURASIP Journal on Advances in Signal Processing. 2021. vol. 2021.
25. Wang N., Dai J., Ying J. UAV Formation Obstacle Avoidance Control Algorithm Based on Improved Artificial Potential Field and Consensus // International Journal of Aeronautical and Space Sciences. 2021. vol. 22. no. 6. pp. 1413–1427.
26. Vicsek T., Czirók A., Ben-Jacob E., Cohen I., Shochet O. Novel type of phase transition in a system of self-driven particles // Physical Review Letters. 1995. vol. 75. no. 6. pp. 1226–1229. DOI: 10.1103/PhysRevLett.75.1226.
27. Riedel M. A Review of Detect and Avoid Standards for Unmanned Aircraft Systems // Aerospace. 2025. vol. 12. no. 4.

Акимов Андрей Анатольевич — канд. физ.-мат. наук, доцент кафедры, кафедра инструментального и прикладного программного обеспечения, Институт информационных технологий ФГБОУ ВО «МИРЭА – Российский технологический университет». Область научных интересов: дифференциальные уравнения, методы оптимального управления,

прикладная информатика. Число научных публикаций — 60. akimov_a@mirea.ru; проспект Вернадского, 78, 119454, Москва, Россия; р.т.: +7(499)600-8080,20135.

Гнатенко Юлия Ахнафовна — канд. физ.-мат. наук, доцент кафедры, кафедра математического моделирования, Стерлитамакский филиал Уфимского университета науки и технологий. Область научных интересов: математическое моделирование, численные методы, разработка программных комплексов. Число научных публикаций — 40. y.a.gnatenko@strust.ru; проспект Ленина, 49, 453100, Стерлитамак, Республика Башкортостан, Россия; р.т.: +7(3473)339-865,322.

Болбаков Роман Геннадьевич — канд. техн. наук, доцент, заведующий кафедрой, кафедра инструментального и прикладного программного обеспечения, Институт информационных технологий ФГБОУ ВО «МИРЭА – Российский технологический университет». Область научных интересов: системный анализ, программное обеспечение, оптимальные задачи, прикладные методы обработки информации. Число научных публикаций — 207. bolbakov@mirea.ru; проспект Вернадского, 78, 119454, Москва, Россия; р.т.: +7(499)600-8080,20135.

A. AKIMOV, Y. GNATENKO, R. BOLBAKOV

A MULTI-LAYER STRATEGY FOR SAFE NAVIGATION AND SWARM DISTRIBUTION OF UAVS IN WILDFIRE MONITORING*Akimov A., Gnatenko Y., Bolbakov R. A Multi-Layer Strategy for Safe Navigation and Swarm Distribution of UAVs in Wildfire Monitoring.*

Abstract. Wildfires are among the most dangerous and least predictable natural hazards, necessitating continuous real-time monitoring of the advancing fire front. Traditional assets – such as satellite imagery or ground observation posts – often lack the responsiveness and completeness required for timely decision-making. A promising alternative is the use of a swarm of unmanned aerial vehicles (UAVs); however, effective coordination under dynamic conditions and constrained communication and computational resources calls for dedicated control algorithms. This work presents a multi-layer control strategy for a UAV swarm that integrates three components. Horizontal navigation is governed by the Artificial Potential Field (APF) method, which attracts agents to the fire-front line while repelling them from obstacles and neighboring vehicles. A distributed consensus protocol stabilizes flight at a common reference altitude, ensuring comparable viewing geometry. To achieve an even distribution along the front, a modified Particle Swarm Optimization (PSO) layer is employed, reducing competition between drones and unnecessary maneuvering. We report a series of computational experiments comparing classical APF with the hybrid APF+PSO scheme for minimizing a swarm motion performance functional. The hybrid approach lowers the objective by nearly an order of magnitude relative to APF alone, reduces behavioral variability, maintains a coordinated altitude without pronounced overshoot, and ensures reliable obstacle avoidance in the presence of a moving front. Minimum inter-drone separations did not fall below the 5-m safety threshold, confirming compliance with safety requirements. The algorithm sustains stable tracking of the moving front over the entire simulation horizon while preserving correct obstacle clearance. Overall, the proposed strategy combines computational simplicity with high reliability. Future work will incorporate onboard sensing (video and thermal cameras), modeling of wind and terrain effects, analysis of communication delays and losses, and extension of the approach to larger UAV teams.

Keywords: artificial potential fields, particle swarm optimization, distributed control, multi-layer strategy, swarm navigation, route optimization, altitude consensus, hybrid algorithms.

References

1. Akhloufi M.A., Couturier A., Castro N.A. Unmanned Aerial Vehicles for Wildland Fires: Sensing, Perception, Cooperation and Assistance. *Drones*. 2021. vol. 5. no. 1.
2. Merino L., Caballero F., Martínez-de-Dios J.R., Maza I., Ollero A. An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement. *Journal of Intelligent & Robotic Systems*. 2012. vol. 65. no. 1. pp. 533–548.
3. Martínez-de-Dios J.R., Merino L., Caballero F., Ollero A. Automatic Forest-Fire Measuring Using Ground Stations and Unmanned Aerial Systems. *Sensors*. 2011. vol. 11. no. 6. pp. 6328–6353.
4. Kosinov D.E. [Use of UAVs for forest-fire monitoring]. Materialy Nats. nauch.-prakt. konf. «Tsirkulyarnaya ekonomika dlya tselei ustoychivogo razvitiya otrassei i territorii» [Proceedings of the National Scientific and Practical Conference «Circular Economy for Sustainable Development of Industries and Territories»]. Voronezh: VGLTU im. G.F. Morozova, 2024. pp. 193–198. (In Russ.).

5. Zhu P., Song R., Zhang J., Xu Z., Gou Y., Sun Z., Shao Q. Multiple UAV Swarms Collaborative Firefighting Strategy Considering Forest Fire Spread and Resource Constraints. *Drones*. 2025. vol. 9. no. 1.
6. Liu Y., Chen C., Wang Y., Zhang T., Gong Y. A fast formation obstacle avoidance algorithm for clustered UAVs based on artificial potential field. *Aerospace Science and Technology*. 2024. vol. 147.
7. Wu R.-Y., Xie X.-C., Zheng Y.-J. Firefighting Drone Configuration and Scheduling for Wildfire Based on Loss Estimation and Minimization. *Drones*. 2024. vol. 8. no. 1. DOI: 10.3390/drones8010017.
8. Kuznetsov A.V. [Systems for forest-fire monitoring using UAVs]. Pozharnaya i avariinaya bezopasnost': materialy XVIII Mezhdunar. konf. [Fire and Emergency Safety: Proceedings of the 18th International Conference]. 2023. pp. 622–626. (In Russ.).
9. Serebryakov A.E., Gura D.A., Drazhetskii D.A., Panchenko E.A. [UAV types and capabilities for monitoring and preventing forest fires]. Nauka. Tekhnika. Tekhnologii (Politekhnicheskii vestnik) – Science. Engineering. Technologies (Polytechnic Bulletin). 2021. no. 4. pp. 175–178. (In Russ.).
10. Debnath D., Vanegas F., Sandino J., Hawary A.F., Gonzalez F.A. A Review of UAV Path-Planning Algorithms and Obstacle Avoidance Methods for Remote Sensing Applications. *Remote Sensing*. 2024. vol. 16. no. 21.
11. Zhu P., Jiang S., Zhang J., Xu Z., Sun Z., Shao Q. Multi-Target Firefighting Task Planning Strategy for Multiple UAVs Under Dynamic Forest Fire Environment. *Fire*. 2025. vol. 8. no. 2.
12. Sun B., Gu Z., Xiong T. Event-Triggered Formation Tracking Control for Unmanned Aerial Vehicles Subjected to Deception Attacks. *Electronics*. 2021. vol. 10. no. 22.
13. Wang T., Zhao S., Xia Y., Pan Z., Tian H. Consensus Control of Large-Scale UAV Swarm Based on Multi-Layer Graph. *Drones*. 2024. vol. 6. no. 12. DOI: 10.3390/drones6120402.
14. Darintsev O., Migranov A. [Analytical Review of Approaches to the Distribution of Tasks for Mobile Robot teams Based on Soft Computing Technologies]. *Informatics and Automation*. 2022. vol. 21. no. 4. pp. 729–757. (In Russ.).
15. Smirnov A.V. [Effect of objective-function ruggedness on minimum localization error]. *Rossiiskii tekhnologicheskii zhurnal* – Russian Technological Journal. 2023. vol. 11. no. 6. pp. 57–67. (In Russ.).
16. Akimov A.A., Sapozhnikova K.A., Gnatenko Y.A. A Discrete Swarm Optimization Modification for the Multi Agent Traveling Salesman Problem. Proc. of the International Russian Smart Industry Conference (SmartIndustryCon). IEEE, 2025. pp. 418–424.
17. Cheng Q., Zhang Z., Du Y., Li Y. Research on Particle Swarm Optimization-Based UAV Path Planning Technology in Urban Airspace. *Drones*. 2024. vol. 8. no. 12.
18. Gorshkov I.F., Akimov A.A. [Dynamic drone routing for delivery]. *Nauchno-tehnicheskii vestnik Povolzh'ya* [Scientific and Technical Bulletin of the Volga Region]. 2025. no. 6. pp. 202–205. (In Russ.).
19. Rimon E., Koditschek D.E. Exact Robot Navigation Using Artificial Potential Functions. *IEEE Transactions on Robotics and Automation*. 1992. vol. 8. no. 5. pp. 501–518. DOI: 10.1109/70.163777.
20. Hao G., Lv Q., Huang Z., Zhao H., Chen W. UAV Path Planning Based on Improved Artificial Potential Field Method. *Aerospace*. 2023. vol. 10. no. 6.
21. Xiong H., Deng G., Liu Y., Wu W. Distributed event-triggered formation control of UGV-UAV heterogeneous multi-agent systems for ground-air cooperation. *Chinese Journal of Aeronautics*. 2024. vol. 37. no. 12. pp. 458–483.

22. Hartley J., Shum H., Ho S., Wang H., Ramamoorthy S. Formation control for UAVs using a Flux Guided approach. *Expert Systems with Applications*. 2022. vol. 205.
23. Partheepan S., Sanati F., Hassan J. Autonomous Unmanned Aerial Vehicles in Bushfire Management: Challenges and Opportunities. *Drones*. 2023. vol. 7. no. 1. DOI: 10.3390/drones7010047.
24. Shao R., Tao R., Liu Y., Yang Y., Li D., Chen J. UAV cooperative search in dynamic environment based on hybrid-layered APF. *EURASIP Journal on Advances in Signal Processing*. 2021. vol. 2021.
25. Wang N., Dai J., Ying J. UAV Formation Obstacle Avoidance Control Algorithm Based on Improved Artificial Potential Field and Consensus. *International Journal of Aeronautical and Space Sciences*. 2021. vol. 22. no. 6. pp. 1413–1427.
26. Vicsek T., Czirók A., Ben-Jacob E., Cohen I., Shochet O. Novel type of phase transition in a system of self-driven particles. *Physical Review Letters*. 1995. vol. 75. no. 6. pp. 1226–1229. DOI: 10.1103/PhysRevLett.75.1226.
27. Riedel M. A Review of Detect and Avoid Standards for Unmanned Aircraft Systems. *Aerospace*. 2025. vol. 12. no. 4.

Akimov Andrey — Ph.D., Associate professor of the department, Department of instrumental and applied software, Institute of Information Technologies, MIREA – Russian Technological University. Research interests: differential equations, optimal control methods, applied informatics. The number of publications — 60. akimov_a@mirea.ru; 78, Vernadsky Ave., 119454, Moscow, Russia; office phone: +7(499)600-8080,20135.

Gnatenko Yuliya — Ph.D., Associate professor of the department, Department of mathematical modeling, Sterlitamak Branch of the Ufa University of Science and Technology. Research interests: mathematical modeling, numerical methods, development of software systems. The number of publications — 40. y.a.gnatenko@strust.ru; 49, Lenin Ave., 453100, Sterlitamak, Republic of Bashkortostan, Russia; office phone: +7(3473)339-865,322.

Bolbakov Roman — Ph.D., Associate Professor, Head of the department, Department of instrumental and applied software, Institute of Information Technologies, MIREA – Russian Technological University. Research interests: systems analysis, software engineering, optimization problems, applied methods of information processing. The number of publications — 207. bolbakov@mirea.ru; 78, Vernadsky Ave., 119454, Москва, Russia; office phone: +7(499)600-8080,20135.

В.М. КРУНДЫШЕВ, М.О. КАЛИНИН

**ОЦЕНКА ЭФФЕКТИВНОСТИ ОБЕСПЕЧЕНИЯ
ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ В СИСТЕМАХ
УМНОГО ГОРОДА НА ОСНОВЕ МОДЕЛИ КОНКУРЕНЦИИ**

Крундышев В.М., Калинин М.О. Оценка эффективности обеспечения информационной безопасности в системах умного города на основе модели конкуренции.

Аннотация. Реализация концепции умного города (smart city) подразумевает переход от традиционных компьютерных сетей, имеющих четкий информационный периметр, к распределенным сетям нового поколения. Для распределенных подсистем умного города свойственны реконфигурируемая сетевая топология, открытость, мобильность узлов и построение защиты информации на базе распределенных реестров данных, что открывает новые возможности для злоумышленников. Ситуация осложняется тем, что скорость создания новых цифровых инфраструктур превосходит скорость разработки средств защиты, отвечающих актуальным вызовам. Учитывая специфические свойства объекта защиты, динамику развития угроз безопасности и ограниченный выбор защитных механизмов, для поддержания высокого уровня защищенности систем умного города необходимо проводить непрерывную оценку эффективности защиты и ее перенастройку. В результате анализа существующих решений по оценке эффективности систем обеспечения информационной безопасности установлено, что они работают в проактивном режиме и не учитывают высокую динамику системы «угрозы-защиты» в системах умного города. В статье представлена построенная модель оценки эффективности обеспечения информационной безопасности, базирующаяся на нелинейной динамической модели конкуренции за влияние на функционирование информационной инфраструктуры. Для поддержания устойчивого состояния системы умного города необходимо выполнение критерия о соотношении скоростей обнаружения и развития компьютерной атаки в инфраструктуре. На разработанном экспериментальном макете эмулированы сценарии развития компьютерных атак «эксплуатация уязвимости ПО», «распределенный отказ в обслуживании», «черная дыра» и «атака большинства» на примере интеллектуальной транспортной сети VANET в инфраструктуре умного города при использовании различных конфигураций системы защиты. В ходе сравнительного эксперимента разных конфигураций системы защиты сети VANET показано, что пример комплекса, реализующего обнаружение атак с помощью сверточной нейросети, динамическую маршрутизацию на базе муравьиного алгоритма и протокол Hashgraph с внедренной моделью доверия, удовлетворяет критерию устойчивости. Применение предложенной модели оценки позволяет обоснованно контролировать и динамически регулировать конфигурацию системы защиты.

Ключевые слова: критерий устойчивости, модель конкуренции, оценка эффективности, распределенный реестр, скорость развития компьютерной атаки, точка устойчивости, умный город.

1. Введение. В последние годы внимание специалистов из разных отраслей экономики приковано к развивающейся технологической концепции умного города (от англ. «smart city»), предполагающей объединение всех основных жизненно важных

подсистем городского хозяйства (ЖКХ, транспорт, медицина, экология, обеспечение правопорядка, водо- и энергоснабжение и пр.) в единую цифровую экосистему [1 – 3]. Согласно расчетам аналитиков McKinsey, к 2030 году умные города будут генерировать почти 70% мирового ВВП [4]. Технологическим базисом подсистем умного города являются компьютерные сети нового поколения, включая Интернет вещей (IoT), сенсорные сети (WSN), сети транспортных средств (VANET) и прочие динамически реконфигурируемые сети устройств, а также системы распределенного реестра, применяемые для организации контролируемого и верифицируемого обмена данными между участниками сети умного города [5 – 8].

Для обеспечения информационной безопасности систем, имеющих постоянную инфраструктуру и четкий периметр, традиционно применяется стандартный перечень средств защиты, таких как межсетевые экраны, антивирусные программы, SIEM- и DLP-системы. На рынке существует ряд решений, предлагаемых крупными производителями и подтврдивших свою эффективность при обнаружении компьютерных атак типа «отказ в обслуживании», при блокировке вредоносных программ, фильтрации фишинговых сообщений и спама. Ведущие компании в области разработки средств защиты десятилетиями накапливали опыт, получая обратную связь от пользователей, и дорабатывали свои решения, делая их более функциональными, эффективными и универсальными. Основными же свойствами систем умного города являются их динамика и неоднородность, что затрудняет применение традиционных методов и средств защиты информации [8 – 10]. Ситуация осложняется тем, что скорость внедрения систем умного города превышает скорость разработки специализированных средств защиты для них, чем активно пользуются злоумышленники. Отсутствие статического периметра защиты, самоорганизация мобильных узлов в отдельные сегменты, децентрализованное хранение больших объемов данных, возможность перемещения узлов сети – все это открывает новые возможности как для прогресса технологий умных городов, так и для нарушителей безопасности, которые реализуют специфические компьютерные атаки, направленные на нарушение устойчивого функционирования систем умных городов и эксплуатирующие новые уязвимости (например, в динамической маршрутизации и в распределенном реестре) [11 – 14].

В таких условиях одной из ключевых проблем является оценка эффективности обеспечения информационной безопасности в системах умного города. Нечеткость структуры объекта защиты и внедрение

новых компьютерных технологий приводит к тому, что формирование единых подходов к построению системы защиты цифровых инфраструктур умного города становится невозможным. С учетом постоянных изменений, происходящих в объекте защиты, и постоянно меняющегося ландшафта угроз безопасности необходимо регулярно проверять адекватность системы обеспечения информационной безопасности умного города с целью выявления ее слабых мест и соответствующей перенастройки защитных механизмов. Для решения поставленной задачи в статье рассматриваются следующие аспекты:

– представлены результаты анализа существующих подходов к оценке эффективности обеспечения информационной безопасности, а также определены требования, которым должна отвечать разрабатываемая модель оценки с учетом характерных особенностей систем умного города;

– для оценки эффективности обеспечения информационной безопасности предложена динамическая модель конкуренции, описывающая взаимодействие разных видов узлов: легитимных узлов и узлов-нарушителей в изменяющейся среде умного города. В данной модели отражается постоянная конкуренция узлов за ресурсы, то есть за характеристики системы умного города, что приводит к эволюционным изменениям в системе;

– на базе сетевого эмулятора разработан экспериментальный макет, поддерживающий модель системы умного города и различные тестовые сценарии компьютерных атак, на котором проведена экспериментальная оценка предложенного решения.

2. Анализ подходов к оценке эффективности систем обеспечения информационной безопасности. В настоящее время выделяются следующие основные подходы к оценке эффективности обеспечения информационной безопасности:

1. Экспертный. Данный подход предполагает использование опыта и знаний экспертов, специализирующихся на защите объектов информатизации. Штатные сотрудники/приглашенные специалисты на основе анализа имеющихся данных принимают решения по оценке эффективности применяемых защитных механизмов. Так, например, в работе [15] представлена экспертная система оценки уровня соответствия системы защиты предъявляемых требованиям. Авторы выделяют три основных этапа: подготовка исходных данных, контроль реализации требований и вычисление итоговых показателей оценки обеспечения информационной безопасности. В работе [16] предложен подход к оценке эффективности, основанный на использовании метода экспертных оценок, в котором полученные показатели уровня

зашщищенности помогают эксперту определиться с принятием правильного решения по рассматриваемым мерам обеспечения безопасности. Преимуществом экспертного подхода является гибкость и высокий экспертный уровень принятых решений. Недостаток заключается в том, что точность оценки зависит от квалификации экспертов. Кроме того, такой подход не позволяет реализовать непрерывную объективную оценку.

2. Статистический. Данный подход предполагает определение показателя эффективности на основе статистических данных. Как правило, оценка эффективности вычисляется с использованием статистических мер, например, таких как среднее, среднеквадратичное отклонение, коэффициент корреляции, для сравнения расчетных и измеренных значений. Например, в статье [17] представлена методика оценки эффективности системы защиты, основанная на стохастическом представлении деструктивных воздействий и процесса ликвидации их последствий. Преимуществом данного подхода является высокая точность оценки эффективности в условиях нехватки данных о текущем состоянии информационной инфраструктуры. Недостатком является то, что точность полученной оценки напрямую зависит от объема имеющихся данных.

3. Вероятностный. Данный подход предполагает использование вероятностных моделей и критериев. В ряде случаев задаются диапазоны значений с определенными вероятностями их наступления. Например, в исследовании [18] представлена модель оценки показателя эффективности обеспечения информационной безопасности, базирующаяся на использовании операционного метода преобразования Лапласа и численного метода решения системы линейных алгебраических уравнений методом Гивенса. В работе [19] построена методика оценивания результативности системы обнаружения веб-бэйджоров, основанная на расчете трех групп частных показателей, характеризующих действенность, ресурсоемкость и оперативность работы системы обнаружения, а также вычислении обобщенного показателя результативности. В исследовании [20] представлена методика оценивания вероятности безотказной работы систем защиты информации от несанкционированного доступа при обеспечении конфиденциальности информации на базе метода эквивалентных схем. Преимущество данного подхода заключается в низкой вероятности ошибок, связанных с субъективными оценками. Недостатком является то, что вероятностные модели могут устареть и перестать быть актуальными в результате изменений информационной инфраструктуры и систем защиты.

4. Нейросетевой. Данный подход предполагает обучение вычислительной модели машинного обучения на наборе данных, содержащем информацию о параметрах объекта защиты, действующих угрозах безопасности и конфигурации системы защиты. В результате обучения на этапе эксплуатации нейросетевая модель может принимать решения о выборе оптимальной конфигурации средств защиты информации. Например, в работах [21, 22] представлен алгоритм модели оценки защищенностии информационной системы на основе нейросети. Для обучения нейросети используется алгоритм обратного распространения ошибки. Преимущество нейросетевого подхода заключается в возможности обнаружения скрытых закономерностей в данных. Недостатком является то, что точность оценки эффективности средств защиты напрямую зависит от обучающего набора данных, в результате чего такое решение требует значительных временных затрат на внедрение и калибровку.

5. На основе нечеткой логики. Данный подход предполагает применение аппарата нечеткой логики для описания текущего состояния объекта защиты, системы обеспечения информационной безопасности и действующих киберугроз. В условиях неопределенности динамически меняющиеся параметры описываются в виде нечетких переменных, также определяется функция принадлежности. Например, в исследовании [23] для оценки уровня защищенностии использован аппарат нечеткой логики, а для оценки стойкости элементов защиты введены и использованы нечеткие переменные «вероятность появления угрозы», «величина ущерба», «степень сопротивляемости». В работах [24, 25] представлены похожие методики оценки эффективности системы защиты распределенных информационных систем, базирующаяся на нечеткой продукционной системе с установленными в результате экспериментов оптимальными параметрами и алгоритмом нечеткого вывода. Преимущество данного подхода заключается в том, что он не требует наличия точной и полной информации. Недостатком является то, что для высокой точности оценки эффективности защиты необходимо предварительно с привлечением экспертов подготовить базу знаний, определив терм-множества и диапазоны.

6. Комбинированный. Предполагается использование ансамбля различных эвристик и алгоритмов для оценки эффективности конфигурации системы защиты и поиска оптимального решения. В ряде случаев для решения задачи оптимизации применяются биоинспирированные методы. Например, в исследовании [26] применяется генетический алгоритм для выбора

оптимальной конфигурации системы защиты информации с учетом изменяющихся условий среды, уровня профессиональной подготовки работников, количества отказов в работе оборудования и скорости развития компьютерной атаки. В работе [27] авторы исследуют применимость гибридного подхода к оперативной оценке защищенности критически важных ресурсов, сочетающего традиционные методы фильтрации Калмана с возможностями искусственных нейросетей. Преимущество комбинированного подхода заключается в его гибкости. Недостатком является высокая сложность вычислений и подбора параметров алгоритма при больших объемах анализируемых данных.

7. Графовый (с использованием методов теории графов). Данный подход предполагает представление информационной инфраструктуры в виде графа, где узлы (вершины) графа представляют собой компоненты системы (например, серверы, устройства, процессы), а ребра графа представляют собой связи между этими компонентами (например, сетевые соединения, зависимости между программными модулями). Математическая модель, представленная в виде набора графов, позволяет описывать и анализировать системы и движение информационных активов и потоков предприятия, их взаимовлияния с целью выявления потенциальных угроз информационной безопасности и оценки эффективности спроектированной системы защиты информации. Например, в исследовании [28] представлен подход к оценке эффективности обеспечения информационной безопасности на основе построения и анализа дерева атак, состоящем из программно-технических атак (направленных на объекты информационной инфраструктуры) и социоинженерных атак (направленных на санкционированных пользователей). В работе [29] представлена динамическая система защиты, состоящая из взаимодействующих подсистем обеспечения безопасности, поддерживающих возможность переключения компонентов внутри одной подсистемы. В статье [30] рассмотрен метод повышения эффективности управления защитой, в основе которого лежит вычисление комплексного показателя защищенности, а также построение графа защищенности, учитывающего реальную структуру компьютерной сети и системы защиты информации. Преимущество графового подхода заключается в том, что он позволяет представить сложную сетевую инфраструктуру в виде наглядной модели, что упрощает понимание топологии сети и связей ее элементов. Недостатком является то, что точность оценки защищенности при использовании данного подхода определяется

непротиворечивостью и качеством входных данных, которые используются для построения графа, а также необходимостью специальных алгоритмов обработки знаний, представленных в виде графов.

8. На основе моделирования состояний системы. Данный подход позволяет анализировать последовательность событий и вероятности переходов между состояниями безопасности, что помогает оценить эффективность мер защиты и выявить слабые места. Защищаемую информационную инфраструктуру можно представить как систему, находящуюся в различных состояниях (например, «защищена», «атакована», «скомпрометирована», «восстановлена»). Например, в исследовании [31] представлена математическая модель, в основу которой положен аппарат сетей Петри-Маркова, получены аналитические соотношения для расчета предложенного показателя на примере жизненного цикла входящих электронных документов с учетом времени выполнения типовых процедур и функций их обработки, времени реализации угроз, а также применения мер защиты. В работе [32] для выбора оптимального набора средств защиты от компьютерных атак использован аппарат поглощающих цепей Маркова. Решаемая задача была сведена к максимизации среднего времени до отказа безопасности при ограничениях на стоимость набора защитных механизмов. Преимущество данного подхода заключается в том, что он позволяет работать с трассой состояний системы и оценивать эффективность защиты в перспективе. Недостатком является то, что подход подразумевает упрощение реальной системы, в результате чего не все факторы, влияющие на ее безопасность, учитываются.

Результаты анализа подходов к оценке эффективности систем обеспечения информационной безопасности представлены в таблице 1.

Таким образом, в результате анализа известных подходов к оценке эффективности систем обеспечения информационной безопасности можно сделать вывод, что большинство рассмотренных решений требуют наличия точных исходных данных об объекте защиты, действующих угрозах безопасности и доступных механизмах защиты. Однако, в быстрымениющихся условиях умного города исходные данные быстро теряют свою актуальность и перестают отражать фактическое состояние системы. В таких условиях наиболее перспективными являются решения, базирующиеся на математических моделях, характеризующих динамику изменений как объекта защиты, так и действующих угроз.

Таблица 1. Результаты анализа подходов

Подход	Особенности	Преимущества	Недостатки
Экспертный	Использование опыта и знаний экспертов	Гибкость и высокий экспертный уровень принятых решений	Точность оценки зависит от квалификации экспертов
Статистический	Определение показателя эффективности на основе статистических данных	Высокая точность оценки эффективности в условиях нехватки данных о текущем состоянии информационной инфраструктуры	Точность оценки зависит от объема имеющихся данных
Вероятностный	Использование вероятностных моделей и критериев	Низкая вероятность ошибок, связанных с субъективными оценками	Риск устаревания вероятностной модели
Нейросетевой	Обучение модели на наборе данных, содержащем информацию о параметрах объекта защиты, действующих угрозах безопасности и конфигурации системы защиты	Возможность обнаружения скрытых закономерностей в данных	Временные затраты на внедрение и калибровку нейросетевой модели
На основе нечеткой логики	Применение аппарата нечеткой логики для описания текущего состояния объекта защиты, системы обеспечения информационной безопасности и действующих киберугроз	Не требует наличия точной и полной информации	Необходимость привлечения экспертов для подготовки базы знаний, определения терм-множеств и диапазонов
Комбинированный	Использование ансамбля различных эвристик и алгоритмов для оценки эффективности конфигурации системы защиты и поиска оптимального решения	Гибкость	Высокая сложность вычислений и подбора параметров алгоритма при больших объемах анализируемых данных
Графовый	Представление информационной инфраструктуры в виде графа, где узлы графа представляют собой компоненты системы, а ребра графа представляют собой связи между этими компонентами	Представление сложной сетевой инфраструктуры в виде наглядной модели	Необходимость использования специальных алгоритмов обработки знаний, представленных в виде графов
На основе моделирования состояний системы	Анализ последовательности событий и вероятности переходов между состояниями безопасности	Работа с трассой состояний системы и оценка эффективности защиты в перспективе	Упрощение реальной системы

Применение методов теории графов и цепей Маркова для описания состояний объекта защиты и системы обеспечения информационной безопасности ограничено необходимостью ввода в реальную систему дополнительного параметра – временного лага между моментом, когда действие осуществляется, и моментом, когда наблюдается его эффект. Учитывая сказанное, для оценки эффективности защиты предлагается разработать динамическую модель без временных задержек, на вход которой подается минимальный объем данных. В рамках исследования предлагается свести задачу оценки эффективности обеспечения информационной безопасности в системах умного города к задаче поиска оптимального решения при ограниченном выборе механизмов защиты.

3. Динамическая модель конкуренции. Учитывая особенности систем умного города, а также наличие в сети двух типов узлов (легитимных узлов и узлов-нарушителей), предлагается провести аналогию с нелинейными динамическими моделями взаимодействия двух конкурирующих видов, применяемых в экологии и других смежных областях науки.

Традиционные природоподобные модели (модели конкуренции видов) без временных задержек состоят из системы дифференциальных уравнений, характеризующих популяцию видов в каждый момент времени [33, 34]. Классическая модель конкуренции, предложенная А.Лоткой и В.Вольтеррой [35], описывается системой дифференциальных уравнений вида (1):

$$\begin{cases} \frac{dx}{dt} = (\alpha - \beta y)x \\ \frac{dy}{dt} = (\delta x - \gamma)y \end{cases}, \quad (1)$$

где x и y – зависимости от времени t , которые характеризуют соответственно, количества видов жертв и хищников; α – вероятность того, что жертвы размножаются; γ – вероятность того, что хищник умрет от голода; β – вероятность того, что жертва будет съедена хищником; δ – вероятность того, что хищнику хватит еды на дальнейшее размножение.

Как правило, для решения прикладных задач применяются модификации классической модели «хищник-жертва». Расширение возможностей классической модели «хищник-жертва» осуществляется путем добавления ограничений на количество ресурсов для жертв, учета влияния окружающей среды, создания пространственной

структуры, а также за счет ввода нескольких видов жертв и хищников [36 – 38]. Так, расширенные модели конкуренции успешно применяются в экологии и медицине. Например, в исследовании [39] рассмотрена возможность применения модели «хищник-жертва» для моделирования процессов, связанных с очисткой сточных вод, где загрязнитель вступает в качестве жертвы, а биологически активный ил – в роли хищника. В исследовании [40] представлена медицинская модель иммунной реакции, в рамках которой описывается взаимодействие между антигеном и антителом. Также, модель конкуренции применяется в компьютерных науках для описания динамики взаимодействия между различными узлами в компьютерной сети, для моделирования процессов, борющихся за обладание ресурсами (например, несколько процессов могут конкурировать за процессорное время или за память), а также в сценариях информационной безопасности, где в роли жертвы выступает сценарий инцидента, а в роли хищника – защитный механизм [41]. Таким образом, учитывая имеющийся успешный опыт применения моделей конкуренции в различных областях, в том числе в компьютерных науках, предлагается применить модель конкуренции без временных задержек для описания взаимодействия компонентов систем умного города и последующей оценки эффективности применяемых защитных механизмов.

Расширение исходной модели и добавление дополнительных факторов и закономерностей, описываемых явными функциями, позволит полно отразить динамику системы умного города с учетом наличия в ней нескольких конкурирующих видов. В качестве конкурирующих видов выступают легитимные узлы и узлы-нарушители. При расширении исходной модели также необходимо учитывать, что информационная инфраструктура умного города характеризуется разным уровнем защищенности узлов. В рамках одной компьютерной сети могут взаимодействовать как оснащенные передовыми средствами защиты центральные серверы и базы данных, так и слабо защищенные устройства и датчики Интернета вещей умного города и систем городского хозяйства. Проэксплуатировав уязвимости ПО слабо защищенных устройств, злоумышленник может создать ботнет, который будет использован для реализации компьютерных атак, направленных на вывод из строя центральных серверов и магистрального сетевого оборудования, реализации атак большинства на системы распределенного реестра и т.д. Учитывая особенности систем умного города и наиболее вероятные сценарии реализации компьютерных атак, при разработке модели оценки

эффективности обеспечения информационной безопасности определены следующие понятия:

- хищник (malicious, M) – устройство, которое осуществляет целенаправленные компьютерную атаку на систему умного города, маршрутизацию и отдельные целевые устройства (устройства-жертвы);
- жертва (normal, N) – устройство, которое выполняет свою целевую функцию и не осуществляет деструктивных действий по отношению к системе умного города;
- инфицированное устройство (zombie, Z) – «устройство-зомби», которое осуществляет деструктивное действие в отношении системы умного города и находится под управлением злоумышленника;
- вакцинированное устройство (protected, P) – устройство, которое в период действия вакцины является более защищенным от атак за счет использования дополнительных средств защиты;
- выведенное из строя устройство (broken, B) – устройство, неспособное в полной мере выполнять целевую функцию (в терминах классической модели – мертвая жертва).

Все множество устройств системы умного города представлено в виде совокупности пяти классов: M (malicious) и Z (zombie) – хищники, N (normal), P (protected) и B (broken) – жертвы (рисунок 1).

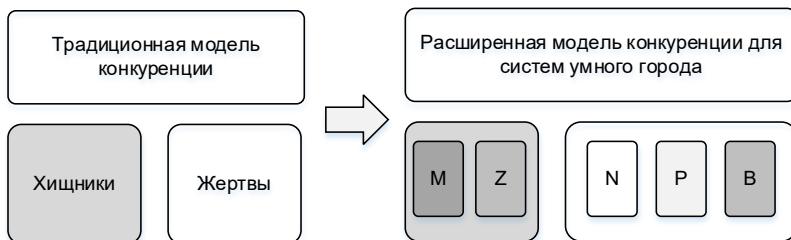


Рис. 1. Классы устройств системы умного города

Устройства классов N и P успешно выполняют целевую функцию, при этом устройства класса P обладают дополнительными механизмами защиты от компьютерных атак (являются вакцинированными). Устройства класса B выведены из строя, при этом они не представляют угрозы для других устройств и могут быть либо восстановлены в класс N , либо со временем перейти в состояние D . Устройства класса M находятся под прямым управлением злоумышленников, реализуют компьютерные атаки и стремятся

перевести устройства из классов P и N в классы Z и B в зависимости от целей и мотивов. Устройства класса Z являются зомби, они реализуют компьютерные атаки на устройства классов N и P , стремясь перевести их в класс B , при этом они могут быть восстановлены в класс P . Состояние D – терминальное состояние, при котором устройство вышло из строя. Устройства класса B переходят в это состояние, если они не были своевременно восстановлены в класс N , а устройства классов M и Z при успешной работе защитных механизмов. На рисунке 2 представлена диаграмма состояний объектов.

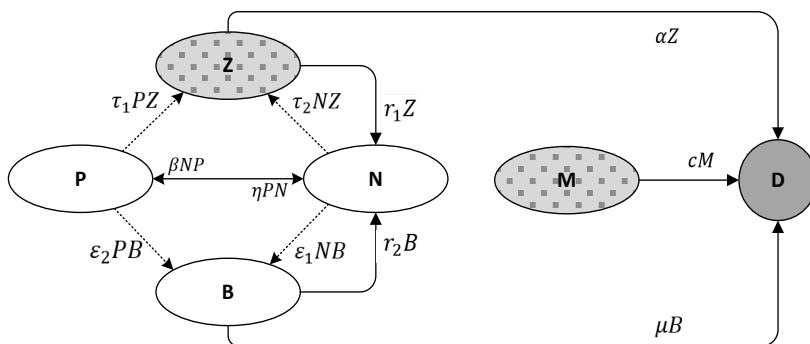


Рис. 2. Диаграмма состояний объектов системы умного города

Устройства классов Z и B могут быть восстановлены в класс N с вероятностями r_1 и r_2 . Устройства класса M инфицируют устройства N и P с вероятностями τ_1 и τ_2 . Под воздействием устройств из классов M и Z жертвы из классов N и P могут перейти в класс B с коэффициентами ε_1 и ε_2 . μ, a, c – коэффициенты вымирания устройств класса B, Z, M . Устройства класса N становятся вакцинированными (переходят в класс P) с вероятностью β . Устойчивость к заражению (вакцинация) пропадает со скоростью, прямо пропорциональной коэффициенту η . Устройства классов Z и M могут вымирать только под воздействием системы защиты – «охотника», которая напрямую влияет на значение коэффициентов a и c . Вероятностные коэффициенты модели определяются на основе статистических данных за прошедший период, а также в результате экспертной оценки. Коэффициенты модели указаны в таблице 2.

Таблица 2. Коэффициенты модели

	<i>N</i>	<i>P</i>	<i>B</i>	<i>Z</i>	<i>M</i>	<i>D</i>
<i>N</i>		β	ε_1	τ_2		
<i>P</i>	η		ε_2	τ_1		
<i>B</i>	r_2					μ
<i>Z</i>	r_1					a
<i>M</i>						c
<i>D</i>						

Исходя из введенных обозначений и модели конкуренции, формальное описание состояний системы умного города и развития компьютерных атак в ней можно представить в виде системы (2):

$$\begin{aligned}
 \frac{dN}{dt} &= n_g N \left(1 - \frac{N}{Q_N}\right) + NP(\eta - \beta) - \varepsilon_1 NB - \tau_2 NZ + r_2 B + r_1 Z - m_N N \\
 \frac{dP}{dt} &= p_g P \left(1 - \frac{P}{Q_P}\right) + NP(\beta - \eta) - \varepsilon_2 PB - \tau_1 PZ - m_P P \\
 \frac{dB}{dt} &= b_g B \left(1 - \frac{B}{Q_B}\right) + \varepsilon_1 NB + \varepsilon_2 PB - r_2 B - B(\mu + m_B) \\
 \frac{dZ}{dt} &= z_g Z \left(1 - \frac{Z}{Q_Z}\right) + \tau_2 NZ + \tau_1 PZ - r_1 Z - aZ \\
 \frac{dM}{dt} &= m_g M \left(1 - \frac{M}{Q_M}\right) - cM
 \end{aligned} \quad (2)$$

В системе уравнений параметры Q_N, Q_P, Q_B, Q_Z, Q_M отражают количество устройств, принадлежащих классам N, P, B, Z, M , соответственно. Коэффициенты n_g, p_g, b_g, z_g, m_g характеризуют рост количества устройств в классах N, P, B, Z, M , соответственно. Параметры m_P, m_B, m_N отражают вероятность промаха «охотника» (попадания по устройствам из классов P, B, N).

4. Формализация решаемой задачи. Определение критерия устойчивости. Согласно предложенной модели, решаемой задачей является максимизация коэффициентов вымирания для классов M и Z , при этом вероятности промаха должны стремиться к нулю (3). Кроме того, учитывая, что устройства класса Z могут быть восстановлены в класс N , относительно класса Z введен коэффициент r_1 , который наравне с a , должен стремиться к максимуму:

$$\begin{cases} m_N \rightarrow 0 \\ m_P \rightarrow 0 \\ m_B \rightarrow 0 \\ r_1 \rightarrow \infty \\ a \rightarrow \infty \\ c \rightarrow \infty \end{cases} \quad (3)$$

Для оценки эффективности обеспечения безопасности систем умного города в условиях воздействия актуальных угроз безопасности определена точка устойчивости системы – идеал.

Идеалом системы (2) является состояние, при котором в модели присутствуют устройства классов N и P , выполняющие свою целевую функцию, а устройства классов M , Z и B отсутствуют.

Точка устойчивости системы $P_0(N_0, P_0, B_0, M_0, Z_0) = P_0(N_0, P_0, 0, 0, 0)$ достижима при значениях (4):

$$\begin{cases} N_0 = Q_N + \frac{Q_N(Q_P p_g n_g - Q_P Q_N(\eta - \beta)(n_g - m_N) - m_P Q_P n_g)(\eta - \beta)}{p_g n_g^2 + n_g Q_P Q_N(\eta - \beta)^2} - \frac{Q_N m_N}{w_g} \\ P_0 = \frac{Q_P p_g n_g - Q_P Q_N(\eta - \beta)(n_g - m_N) - m_P Q_P n_g}{p_g n_g + Q_P Q_N(\eta - \beta)^2} \\ B_0 = 0 \\ M_0 = 0 \\ Z_0 = 0 \end{cases} \quad (4)$$

Тогда для достижения точки устойчивости необходимо решить задачу оптимизации функции «охотника» (5):

$$h_\Phi(t) \rightarrow \max. \quad (5)$$

Функция $h_\Phi(t)$ имеет динамический параметр $\Phi = \{\varphi_1, \dots, \varphi_n\}$, который представляет собой исследуемый в данный момент времени t набор входных данных: параметры системы умного города, доступные вычислительные ресурсы, текущий уровень угроз безопасности. На основе входных данных $\{\Phi_0, t_0\}$ функция $h_\Phi(t)$ определяет, какой из защитных механизмов должен быть выбран для обеспечения наиболее точного и быстрого анализа угроз и реагирования на них.

Критерием устойчивости защищаемой системы служит совокупность условий (6) (скорость вымирания устройств- злоумышленников и устройств-зомби выше, чем скорость перехода устройств из нормального состояния в зараженное или выведенное из строя, при этом количество ложных срабатываний не должно превышать λ , при $Q_M > 0$ и $Q_Z > 0$):

$$\begin{cases} m_N \leq \lambda \\ m_P \leq \lambda \\ m_B \leq \lambda \\ a > \varepsilon_1 \\ a > \varepsilon_2 \\ a > \tau_1 \\ a > \tau_2 \\ c > \varepsilon_1 \\ c > \varepsilon_2 \\ c > \tau_1 \\ c > \tau_2 \end{cases} \quad (6)$$

Таким образом, в соответствии с разработанной моделью эффективная защита должна обеспечить выполнение системы (6).

5. Экспериментальное исследование. На базе сетевого эмулятора NS-3 разработан экспериментальный макет, включающий имитационные модели типовых систем умного города: сеть транспортных средств (сеть VANET), промышленный интернет вещей (ПоТ) и сервис управления энергоресурсами. При запуске сценария пользователю необходимо указать ряд параметров: город, общее количество узлов в сети, плотность расположения придорожной инфраструктуры (базовых станций, умных светофоров, электронных табло, АЗС и т.д.) и транспортных средств, максимальную скорость движения автомобилей, протокол маршрутизации сетевого трафика (реактивный AODV или проактивный OLSR). Также необходимо установить параметры моделирования компьютерных атак (указав тип атаки, время начала и окончания атаки, количество узлов- злоумышленников). Далее в зависимости от выбранных параметров запускается определенный сценарий моделирования, наблюдать за ходом моделирования можно с использованием визуализатора NetAnim. В процессе моделирования генерируются синтетические данные трех типов: дамп сетевого трафика, таблицы маршрутизации и общая статистика о состоянии системы умного города (текущая пропускная способность, количество доставленных и потерянных сетевых пакетов и т.д.).

На рисунке 3 представлен пример экспериментального сценария, в котором злоумышленник последовательно реализует компьютерные атаки на динамическую маршрутизацию и систему распределенного реестра, используемые в сети транспортных средств VANET. Данный сценарий предполагает сетевое взаимодействие

узлов-автомобилей и объектов придорожной инфраструктуры умного города.

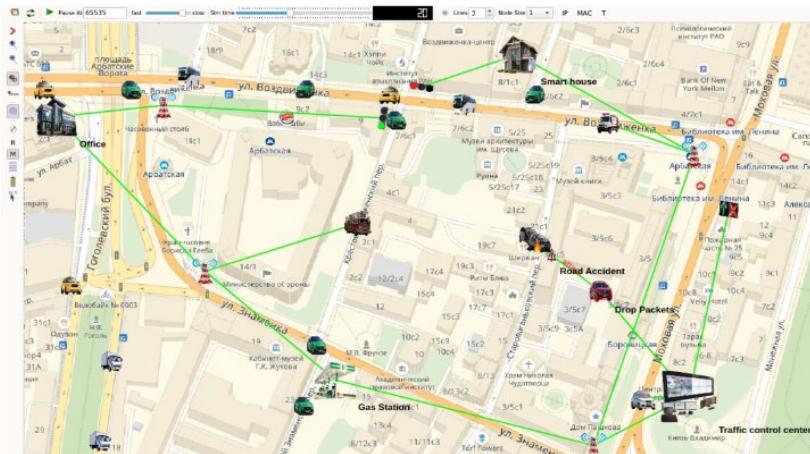


Рис. 3. Моделирование «атаки большинства» на распределенный реестр в сети транспортных средств (VANET) умного города

В ходе рассматриваемого сценария два автомобиля попадают в ДТП, после чего производят попытку отправить соответствующее сообщение в центр управления дорожным движением. Злоумышленник реализует классическую атаку «черная дыра» (blackhole attack) [42], направленную на нарушение маршрутизации между узлами, в результате чего отбрасываются сетевые пакеты, полученные от автомобилей, попавших в ДТП, и вследствие этого спасательные службы не получают сообщение об автомобильной аварии и не прибывают на место происшествия. Далее нарушитель безопасности реализует известную «атаку большинства» (majority attack, 51% attack) [43], нацеленную на используемый в системе распределенный реестр. Атака большинства возникает, когда злоумышленник (группа злоумышленников) получает контроль над более чем 50% вычислительной мощности сети реестра, что позволяет манипулировать консенсусом – в таком случае атакующий может проводить двойное расходование средств, исключать транзакции и изменять порядок транзакций, а также нарушать работу сети, подрывая ее децентрализованность и доверие со стороны пользователей. В рассматриваемом сценарии успешная атака большинства ставит под угрозу целостность распределенного реестра, в результате чего приостанавливается подтверждение новых транзакций, и, как

следствие, пострадавшая сторона не получает страховую выплату от страховой компании за произошедшее ДТП.

Система защиты, состоящая из набора детекторов, реализована в виде отдельного программного модуля. Для обнаружения вредоносной активности используются как традиционные эвристические, пороговые и сигнатуры методы защиты (эксперимент 1), так и современные средства – обнаружение атак с помощью сверточной нейросети, динамическую маршрутизацию на базе муравьиного алгоритма и протокол блокчейна Hashgraph с внедренной моделью доверия (эксперимент 2). На вход системе в режиме реального времени подаются сгенерированные в ходе моделирования синтетические данные. На основе анализа полученных данных системой принимается решение об обнаружении и блокировке узла-нарушителя. Также непрерывно работает программный модуль, реализующий созданную модель оценки эффективности системы защиты. В ходе моделирования непрерывно ведется оценка количества узлов разных типов.

Для рассматриваемого демосценария на рисунках 4 и 5 показана запротоколированная динамика количества узлов каждого класса под воздействием компьютерных атак «черная дыра» (начало в точке 40 сек.) и «атака большинства» (начало в точке 220 сек.).

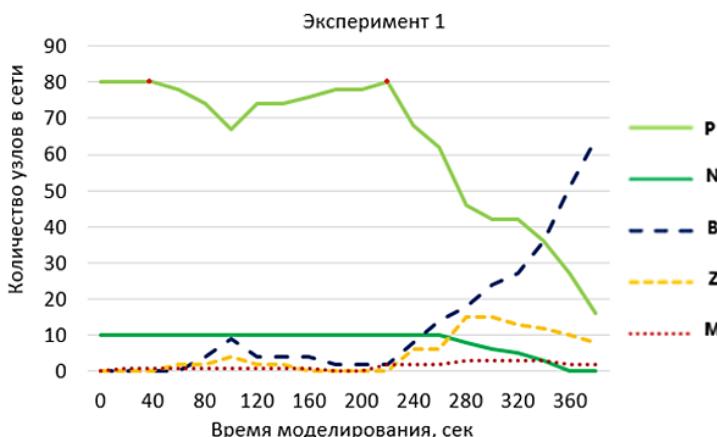


Рис. 4. Динамика количества узлов (эксперимент 1)

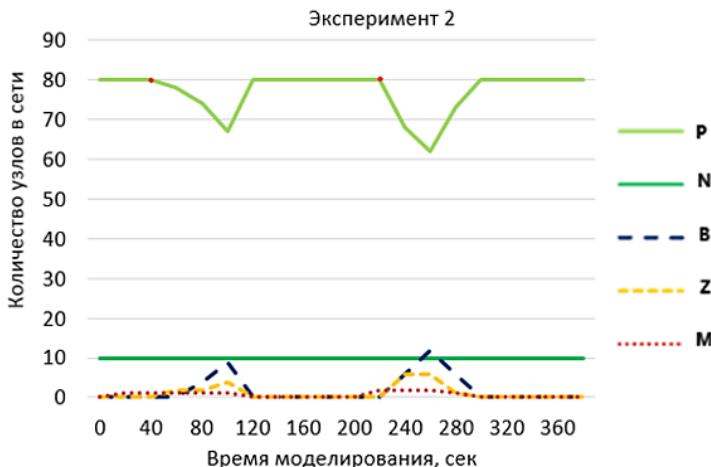


Рис. 5. Динамика количества узлов (эксперимент 2)

Система обеспечения информационной безопасности, использованная в первом эксперименте (рисунок 4), не соответствует установленному критерию устойчивости. При первой атаке в точке, соответствующей отсчету времени 40 сек., нарушитель своевременно обнаружен и изолирован, в результате чего маршрутизация сетевого трафика восстанавливается ко времени 220 сек. Однако, вторая компьютерная атака обнаружена слишком поздно, что привело к нарушению целостности распределенного реестра и остановке транзакций. В ходе альтернативного сценария (рисунок 5) система защиты с адаптированной конфигурацией детекторов своевременно обнаружила обе атаки и изолировала узлы-нарушителей, в результате чего сеть VANET вернулась в рабочее состояние.

Для проведения более масштабного эксперимента разработан сценарий, в котором злоумышленник последовательно реализует серию компьютерных атак на информационную инфраструктуру умного города. Первая атака – получение контроля над слабозащищенными устройствами умного города за счет эксплуатации уязвимости ПО. Вторая атака – распределенная атака типа «отказ в обслуживании» (DDoS-атака) на центральные узлы сети. При реализации данной атаки злоумышленник использует взломанные в ходе первой атаки узлы-зомби. Третья атака – атака «черная дыра», направленная на нарушение маршрутизации сетевого трафика и, как следствие, нарушение стабильной работы сетевого оборудования (базовых станций, коммутаторов и маршрутизаторов). Четвертая

атака – «атака большинства», направленная на нарушение работы системы распределенного реестра. В результате проведения данных атак функционирование сети умного города будет полностью остановлено.

В качестве защитных механизмов реализованы различные методы, предложенные в предыдущих работах авторов. Так, для обнаружения вредоносных сигнатур, предназначенных для взлома слабозащищенных устройств умного города, и обнаружения DDoS-атак реализован метод на основе сверточной нейросети (в таблице 2 – *CNN*) [44]. Преимуществом данного решения является возможность быстрого анализа больших объемов сетевого трафика. Для обнаружения атаки типа «черная дыра» использованы методы на основе роевого интеллекта: муравьиного алгоритма (в таблице 2 – *Ant*) и капель воды (в таблице 2 – *Wat*) [45]. Преимуществом данного решения является его применимость на узлах с низкой вычислительной мощностью и в условиях централизованности сети, что характерно для инфраструктур умного города. Для обнаружения «атаки большинства» реализован механизм консенсуса на базе протокола Hashgraph, дополненный моделью доверия (в таблице 2 – *Hash*) [46]. Преимуществом данного защитного механизма является возможность выявления и изоляции вредоносных узлов на ранних этапах работы сети, снижая их влияние на процесс голосования и тем самым повышая византийскую отказоустойчивость распределенного реестра, а также устойчивость системы.

В ходе экспериментов тестировались различные комбинации защитных механизмов, включая традиционный подход, в котором используется сигнатурный детектор атак, и переборные сочетания альтернативных защитных механизмов. В таблице 2 представлены результаты оценки эффективности тестовых конфигураций защиты, полученные с использованием разработанной модели. Количество ложных срабатываний не должно превышать $\lambda=0,03$ (3%). В соответствии с введенным критерием устойчивости (6) символ « \rightarrow » означает, что в данный момент в сети нет узлов того типа, для которого рассчитывается коэффициент (например, при реализации первой атаки, целью которой является эксплуатация уязвимости ПО, в сети нет узлов-зомби и узлов, выведенных из строя). Красным цветом и перечеркнутыми знаками сравнения отмечены те условия из критерия (6), которые не выполняются.

В результате сравнительного анализа разных конфигураций установлено, что система защиты, состоящая из набора «сверточная нейросеть + муравьиный алгоритм + протокол Hashgraph,

дополненный моделью доверия», соответствует заданному критерию устойчивости. Данная конфигурация системы защиты может быть результативно использована для защиты сети умного города.

Таблица 2. Сравнительная оценка эффективности различных конфигураций системы защиты

Комбинация средств защиты	Экспл. уязв. ПО	DDoS-атака	Атака «черная дыра»	Атака большинства
<i>Традиционный детектор атак на базе контроля сигнатур</i>	$0,05 \pm 0,03$	$0,02 \leq 0,03$	$0,24 \pm 0,03$	$0,36 \pm 0,03$
	$0,04 \pm 0,03$	$0,02 \leq 0,03$	$0,17 \pm 0,03$	$0,31 \pm 0,03$
	—	$0 \leq 0,03$	$0,22 \pm 0,03$	$0,27 \pm 0,03$
	—	$0,21 > 0,52$	—	—
	—	$0,21 > 0,42$	—	—
	—	$0,21 > 0$	—	—
	—	$0,21 > 0$	—	—
	$0,34 > 0$	$0,36 > 0,52$	$0,21 > 0$	$0,12 > 0$
	$0,34 > 0$	$0,36 > 0,42$	$0,21 > 0$	$0,12 > 0$
	$0,34 > 0,53$	$0,36 > 0$	$0,21 > 0$	$0,12 > 0$
	$0,34 > 0,23$	$0,36 > 0$	$0,21 > 0$	$0,12 > 0$
...
<i>CNN + Ant + Hash</i>	$0,01 \leq 0,03$	$0,02 \leq 0,03$	$0,01 \leq 0,03$	$0 \leq 0,03$
	$0,01 \leq 0,03$	$0,02 \leq 0,03$	$0,01 \leq 0,03$	$0 \leq 0,03$
	—	$0 \leq 0,03$	$0 \leq 0,03$	$0 \leq 0,03$
	—	$0,44 > 0,31$	—	—
	—	$0,44 > 0,21$	—	—
	—	$0,44 > 0$	—	—
	—	$0,44 > 0$	—	—
	$0,47 > 0$	$0,44 > 0,31$	$0,48 > 0$	$0,65 > 0$
	$0,47 > 0$	$0,44 > 0,21$	$0,48 > 0$	$0,65 > 0$
	$0,47 > 0,22$	$0,44 > 0$	$0,48 > 0$	$0,65 > 0$
	$0,47 > 0,11$	$0,44 > 0$	$0,48 > 0$	$0,65 > 0$
...
<i>CNN + Wat + PoS</i>	$0,01 \leq 0,03$	$0,02 \leq 0,03$	$0,04 \pm 0,03$	$0,04 \pm 0,03$
	$0,01 \leq 0,03$	$0,02 \leq 0,03$	$0,03 \leq 0,03$	$0,03 \leq 0,03$
	—	$0 \leq 0,03$	$0,02 \leq 0,03$	$0,01 \leq 0,03$
	—	$0,44 > 0,31$	—	—
	—	$0,44 > 0,21$	—	—
	—	$0,44 > 0$	—	—
	—	$0,44 > 0$	—	—
	$0,47 > 0$	$0,44 > 0,31$	$0,39 > 0$	$0,42 > 0$
	$0,47 > 0$	$0,44 > 0,21$	$0,39 > 0$	$0,42 > 0$
	$0,47 > 0,22$	$0,44 > 0$	$0,39 > 0$	$0,42 > 0$
	$0,47 > 0,11$	$0,44 > 0$	$0,39 > 0$	$0,42 > 0$

Например, для другой конфигурации средств защиты, где используется детектор на базе сверточной нейросети, алгоритм капель воды (*Wat*) и протокол консенсуса *PoS*, большинство условий критерия также выполняется, однако при обнаружении атаки «черная дыра» и

«атаки большинства» количество ложных срабатываний превышает порог, а скорость вымирания узлов-нарушителей значительно снижается по сравнению с предыдущей рассмотренной конфигурацией.

6. Заключение. Проведенное исследование позволило установить, что оценка эффективности систем защиты умного города должна базироваться на динамических математических моделях, учитывающих эволюцию как объекта защиты – защищаемой инфраструктуры, так и атакующей стороны – объекта угроз. В данном исследовании построена модель оценки эффективности обеспечения информационной безопасности в системах умного города, базирующаяся на модели конкуренции. Разработанная модель демонстрирует, что устойчивость системы достигается при условии преобладания скорости вымирания злоумышленников и устройств-зомби над скоростью заражения или вывода из строя нормальных узлов.

С использованием разработанного экспериментального макета систем умного города проведено моделирование развития компьютерных атак типа «эксплуатация уязвимости ПО», «распределенный отказ в обслуживании», «черная дыра» и «атака большинства» в сети транспортных средств VANET и противодействия им различных комбинаций защитных механизмов. Экспериментальная верификация модели на макете подтвердила ее применимость для анализа атак различных типов. Разработанная модель позволяет в динамике определять оптимальную конфигурацию системы защиты для конкретных условий эксплуатации и обеспечивать устойчивость систем умного города к компьютерным атакам. При этом продемонстрировано, что комбинация методов машинного обучения, роевых алгоритмов и механизмов консенсуса обеспечивает высокую эффективность защиты, что критически важно для обеспечения устойчивости инфраструктуры умного города в условиях постоянно меняющегося ландшафта угроз.

План дальнейших исследований включает изучение масштабируемости предложенной модели оценки в условиях сверхбольших сетей и разработку среды тестирования защитных систем в условиях неопределенности и частичной наблюдаемости угроз.

Литература

1. Oliha J.S., Biu P.W., Obi O.C. Securing the Smart City: A Review of Cybersecurity Challenges and Strategies // Engineering Science and Technology Journal. 2024. vol. 5. no. 2. pp. 496–506.

-
- 2. Pavao J., Bastardo R., Rocha N.P. Cyber Resilience and Smart Cities, a Scoping Review // 18th Iberian Conference on Information Systems and Technologies (CISTI). 2023. pp. 1-6.
 - 3. Romani G.F., Pinochet L.H.C., Pardim V.I., de Souza C.A. Security as a key factor for the smart city, citizens' trust, and the use of technologies // Revista de Administracao Publica. 2023. vol. 57. no. 2.
 - 4. European Commission. Welcome to 2030: The Mega-trends. URL: <https://ec.europa.eu/assets/epsc/pages/espas/chapter1.html> (дата обращения: 26.06.2025).
 - 5. Tushkanova O., Levshun D., Branitskiy A., Fedorchenko E., Novikova E., Kotenko I. Detection of Cyberattacks and Anomalies in Cyber-Physical Systems: Approaches, Data Sources, Evaluation // Algorithms. 2023. vol. 16. no. 2.
 - 6. Петренко А.А., Петренко С.А. Технологии обеспечения киберустойчивости // Защита информации. Инсайд. 2021. № 6(102). С. 13–19.
 - 7. AlSelami F.A. On the Implementation and Development of Smart Cities based on IoT Technology // International Transaction Journal of Engineering, Management, & Applied Sciences & Technologies. 2021. vol. 12(7). pp. 1–12. DOI: 10.14456/ITJEMAST.2021.144.
 - 8. Ullah A., Anwar S.M., Li J., Nadeem L., Mahmood T., Rehman A., Saba T. Smart cities: The role of Internet of Things and machine learning in realizing a data-centric smart environment // Complex and Intelligent Systems. 2024. vol. 10. pp. 1607–1637.
 - 9. Ismagilova E., Hughes L., Rana N.P., Dwivedi Y.K. Security, Privacy and Risks Within Smart Cities: Literature Review and Development of a Smart City Interaction Framework // Information Systems Frontiers. 2022. vol. 24. pp. 393–414. DOI: 10.1007/s10796-020-10044-1.
 - 10. Sharma S., Mishra N. Horizons recent trends in the security of smart cities: Exploratory analysis using latent semantic analysis // Journal of Intelligent and Fuzzy Systems. 2024. vol. 46. pp. 579–596.
 - 11. Павленко Е.Ю. Исследование влияния атак на структурные и параметрические метрики сетей с адаптивной топологией // Вопросы кибербезопасности. 2023. № 4(56). С. 65–71.
 - 12. Waseem Anwar R., Ali S. Smart Cities Security Threat Landscape: A Review // Computing and Informatics. 2022. vol. 41. pp. 405–423.
 - 13. Kwon H.J., Salim M.M., Park J.H. Recent Trends on Smart City Security: A Comprehensive Overview // Journal of Information Processing Systems. 2023. vol. 19(1). pp. 118–129. DOI: 10.3745/JIPS.03.0182.
 - 14. Telo J. Smart City Security Threats and Countermeasures in the Context of Emerging Technologies // Journal of Intelligent Automation and Computing. 2023. vol. 6. no. 1. pp. 31–45.
 - 15. Люльченко А.Н. Экспертная система оценки эффективности защиты информации // Защита информации. INSIDE. 2016. № 4. С. 20–24.
 - 16. Евдокимов О.Г., Гавдан Г.П., Резниченко С.А. Подход к оценке эффективности системы обеспечения информационной безопасности распределенной системы передачи данных // Безопасность информационных технологий. 2022. Т. 29. № 2. С. 57–70.
 - 17. Анисимов Е.Г., Анисимов В.Г., Гарькушев А.Ю., Селиванов А.А. Показатели эффективности межведомственного информационного взаимодействия при управлении обороной государства // Вопросы оборонной техники. Серия 16: Технические средства противодействия терроризму. 2016. № 7-8(97-98). С. 12–16.
 - 18. Дровникова И.Г., Мещерякова Т.В., Попов А.Д., Рогозин Е.А., Ситник С.М. Математическая модель оценки эффективности систем защиты информации с

- использованием преобразования Лагласса и численного метода Гивенса // Труды СПИИРАН. 2017. № 3(52). С. 234–258. DOI: 10.15622/sp.52.11.
19. Боровков В.Е., Ключарёв П.Г., Денисенко Д.И. Методика оценивания результативности функционирования систем обнаружения веб-бэковоров // Информатика и автоматизация. 2025. Т. 24. № 1. С. 125–162. DOI: 10.15622/ia.24.1.6.
20. Бокова О.И., Дровникова И.Г., Етепнев А.С., Рогозин Е.А., Хвостов В.А. Методики оценивания надежности систем защиты информации от несанкционированного доступа в автоматизированных системах // Труды СПИИРАН. 2019. Т. 18. № 6. С. 1301–1332. DOI: 10.15622/sp.2019.18.6.1301-1332.
21. Трапезников Е.В. Алгоритм модели оценки защищенности информационной системы на основе нейронной сети // Известия Тульского государственного университета. Технические науки. 2017. № 2. С. 312–318.
22. Zhang L., Liu Y. Network Security Prediction and Situational Assessment Using Neural Network-based Method // Journal of Cyber Security and Mobility. 2023. vol. 12. no. 4. pp. 547–568. DOI: 10.13052/jcsm2245-1439.1245.
23. Авдошин А.С. Оценка защищенности информационной системы методами нечеткой логики // Вестник Самарского государственного технического университета. Серия: Технические науки. 2005. № 32. С. 191–193.
24. Миняев А.А., Красов А.В. Методика оценки эффективности системы защиты информации территориально-распределенных информационных систем // Вестник Санкт-Петербургского государственного университета технологии и дизайна. Серия 1: Естественные и технические науки. 2020. № 3. С. 26–32.
25. Atlam H.F., Walters R.J., Wills G.B., Daniel J. Fuzzy Logic with Expert Judgment to Implement an Adaptive Risk-Based Access Control Model for IoT // Mobile Networks and Applications. 2021. vol. 26. pp. 2545–2557. DOI: 10.1007/s11036-019-01214-w.
26. Космачева И.М., Давидюк Н.В., Сибикина И.В., Кучин И.Ю. Модель оценки эффективности конфигурации системы защиты информации на базе генетических алгоритмов // Моделирование, оптимизация и информационные технологии. 2020. Т. 8. № 3. DOI: 10.26102/2310-6018/2020.30.3.022.
27. Котенко И.В., Парашук И.Б. Особенности оперативной оценки защищенности критически важных ресурсов на основе аддитивной нейросетевой фильтрации // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2023. № 3. С. 55–64.
28. Котенко И.В., Степашкин М.В., Котенко Д.И., Дойникова Е.В. Оценивание защищенности информационных систем на основе построения деревьев социоинженерных атак // Известия высших учебных заведений. Приборостроение. 2011. Т. 54. № 12. С. 5–9.
29. Исмагилова А.С., Шагапов И.А., Салов И.В. Теоретико-графовая интерпретация системы защиты информации // Инженерный вестник Дона. 2024. № 9. С. 171–179.
30. Козленко А.В., Авраменко В.С., Саенко И.Б., Кий А.В. Метод оценки уровня защиты информации от НСД в компьютерных сетях на основе графа защищенности // Труды СПИИРАН. 2012. № 2(21). С. 41–55. DOI: 10.15622/sp.21.3.
31. Язов Ю.К., Авсентьев О.С., Рубцова И.О. К вопросу об оценке эффективности защиты информации в системах электронного документооборота // Вопросы кибербезопасности. 2019. № 1(29). С. 25–34.
32. Горюхова В.Ф. Оптимизация выбора средств защиты от атак с использованием поглощающих марковских цепей // Материалы IV Всероссийской научно-

- практической конференции с международным участием «Системы управления, информационные технологии и математическое моделирование». Омский государственный технический университет, 2022. С. 126–134.
33. Колмогоров А.Н. Качественное изучение математических моделей динамики популяций. // Проблемы кибернетики. 1972. Т. 5. № 2. С. 101–106.
 34. Базыкин А.Д. Математическая биофизика взаимодействующих популяций // Академия наук СССР, Научно-исследовательский вычислительный центр. М.: Наука, 1985. 181 с.
 35. Титов В.А., Вейнберг Р.Р. Анализ существующих динамических моделей на базе системы уравнений Лотки-Вольтерры «хищник-жертва» // Фундаментальные исследования. 2016. № 8-2. С. 409–413.
 36. Братусь А.С., Новожилов А.С., Платонов А.П. Динамические системы и модели биологии // М.: Физматлит, 2011. 400 с.
 37. Романов М.Ф., Федоров М.П. Математические модели в экологии: Учеб. пособие // СПб.: Иван Федоров, 2003. 239 с.
 38. Вольтерра В. Математическая теория борьбы за существование // М.-Ижевск: Институт компьютерных исследований, 2004. 288 с.
 39. Братусь А.С., Мещерин А.С., Новожилов А.С. Математические модели взаимодействия загрязнения с окружающей средой // Вестник МГУ. Серия «Вычислительная математика и кибернетика». 2001. Т. 6.
 40. Марчук Г.И. Математические модели в иммунологии и медицине // М.: Наука, 1985.
 41. Минаев В.А., Сычев М.П., Вайц Е.В., Грачева Ю.В. Математическая модель «хищник-жертва» в системе информационной безопасности // Информация и безопасность. 2016. Т. 19. № 3. С. 397–400.
 42. Kamis N.H., Yassin W., Abdollah M.F., Razak S.F.A., Yogarayan S. Blackhole attacks in internet of things networks: a review // Indonesian Journal of Electrical Engineering and Computer Science. 2023. vol. 30. pp. 1080–1090.
 43. Aponte-Novoa F.A., Orozco A.L.S., Villanueva-Polanco R., Wightman P. The 51% Attack on Blockchains: A Mining Behavior Study // IEEE Access. 2021. vol. 9. pp. 140549–140564.
 44. Kalinin M., Krundyshev V. Security intrusion detection using quantum machine learning techniques // Journal of Computer Virology and Hacking Techniques. 2023. vol. 19. no. 1. pp. 125–136.
 45. Krundyshev V., Kalinin M., Zegzhda P. Artificial swarm algorithm for VANET protection against routing attacks // IEEE Industrial Cyber-Physical Systems (ICPS). 2018. pp. 795–800.
 46. Васильев О.С., Крундышев В.М. Защита систем распределенного реестра умного города на основе модели доверия // Материалы 34-й научно-технической всероссийской конференции «Методы и технические средства обеспечения безопасности информации». СПб: Изд-во Политехнического университета, 2025. С. 109–110.

Крундышев Василий Михайлович — канд. техн. наук, доцент, институт компьютерных наук и кибербезопасности, Санкт-Петербургский политехнический университет Петра Великого. Область научных интересов: методы искусственного интеллекта для компьютерной безопасности, модели безопасности, оценка безопасности. Число научных публикаций — 120. vmk@ibks.spbstu.ru; Политехническая улица, 29, 195251, Санкт-Петербург, Россия; р.т.: +7(812)552-7632.

Калинин Максим Олегович — д-р техн. наук, профессор, институт компьютерных наук и кибербезопасности, Санкт-Петербургский политехнический университет Петра

Великого. Область научных интересов: анализ киберрисков, машинное обучение для кибербезопасности, киберустойчивость, модели безопасности киберфизических систем. Число научных публикаций — 320. max@ibks.spbstu.ru; Политехническая улица, 29, 195251, Санкт-Петербург, Россия; р.т.: +7(812)552-7632.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 24-11-20005, <https://rscf.ru/project/24-11-20005/>, грант Санкт-Петербургского научного фонда (договор № 24-11-20005 о предоставлении регионального гранта).

V. KRUNDYSHEV, M. KALININ

EVALUATION OF INFORMATION SECURITY EFFICIENCY IN SMART CITY SYSTEMS BASED ON A COMPETITION MODEL

Krundyshev V., Kalinin M. Evaluation of Information Security Efficiency in Smart City Systems Based on a Competition Model.

Abstract. The implementation of the smart city concept implies a transition from traditional computer networks with a clear information perimeter to next-generation networks. Distributed subsystems of a smart city are characterized by a reconfigurable network topology, openness, node mobility, and the construction of information protection based on distributed ledgers, which also opens up new opportunities for intruders. The situation is complicated by the fact that the speed of creating new digital infrastructures exceeds the speed of developing security tools that meet current challenges. Given the specific properties of the secured object, the dynamics of security threats, and the limited choice of security mechanisms, it is necessary to continuously evaluate the security efficiency and reconfigure it to maintain a higher level of security. As a result of the analysis of existing solutions for information security evaluation, it was found that they operate in a proactive mode and do not take into account the high dynamics of the "threat-protection" system. This paper presents a constructed model for evaluating the efficiency of information security, based on a nonlinear dynamic model of competition for influence on the functioning of the information infrastructure. To maintain a sustainable state of the smart city system, it is necessary to meet the criterion on the ratio of the speed of detection and development of a computer attack in the infrastructure. The developed experimental model emulated the scenarios of development of computer attacks "exploitation of software vulnerability", "distributed denial of service", "black hole", and "majority attack" using the test sample of the intelligent transport network VANET in the smart city in various configurations of the security system. During the comparative analysis of different configurations of the VANET security system, it was shown that a test case implementing attack detection using a convolutional neural network, dynamic routing based on the ant swarm algorithm, and the Hashgraph protocol with an embedded trust model satisfies the sustainability criterion. The use of the proposed evaluation model allows for reasonable control and dynamic adjustment of the security configuration.

Keywords: distributed ledger, sustainability criterion, competition model, efficiency assessment, speed of computer attack, sustainability point, smart city.

References

1. Oliha J.S., Biu P.W., Obi O.C. Securing the Smart City: A Review of Cybersecurity Challenges and Strategies. *Engineering Science and Technology Journal*. 2024. vol. 5. no. 2. pp. 496–506.
2. Pavao J., Bastardo R., Rocha N.P. Cyber Resilience and Smart Cities, a Scoping Review. 18th Iberian Conference on Information Systems and Technologies (CISTI). 2023. pp. 1-6.
3. Romani G.F., Pinochet L.H.C., Pardim V.I., de Souza C.A. Security as a key factor for the smart city, citizens' trust, and the use of technologies. *Revista de Administracao Publica*. 2023. vol. 57. no. 2.
4. European Commission. Welcome to 2030: The Mega-trends. Available at: <https://ec.europa.eu/assets/epsc/pages/espas/chapter1.html> (accessed 26.06.2025).

5. Tushkanova O., Levshun D., Branitskiy A., Fedorchenko E., Novikova E., Kotenko I. Detection of Cyberattacks and Anomalies in Cyber-Physical Systems: Approaches, Data Sources, Evaluation. Algorithms. 2023. vol. 16. no. 2.
6. Petrenko A.A., Petrenko S.A. [Cyber Resilience Technologies]. Zashhita Informacii. Insajd – Information Security. Inside. 2021. no. 6(102). pp. 13–19. (In Russ.).
7. AlSelami F.A. On the Implementation and Development of Smart Cities based on IoT Technology. International Transaction Journal of Engineering, Management, & Applied Sciences & Technologies. 2021. vol. 12(7). pp. 1–12. DOI: 10.14456/ITJEMAST.2021.144.
8. Ullah A., Anwar S.M., Li J., Nadeem L., Mahmood T., Rehman A., Saba T. Smart cities: The role of Internet of Things and machine learning in realizing a data-centric smart environment. Complex and Intelligent Systems. 2024. vol. 10. pp. 1607–1637.
9. Ismagilova E., Hughes L., Rana N.P., Dwivedi Y.K. Security, Privacy and Risks within Smart Cities: Literature Review and Development of a Smart City Interaction Framework. Information Systems Frontiers. 2022. vol. 24. pp. 393–414. DOI: 10.1007/s10796-020-10044-1.
10. Sharma S., Mishra N. Horizoning recent trends in the security of smart cities: Exploratory analysis using latent semantic analysis. Journal of Intelligent and Fuzzy Systems. 2024. vol. 46. pp. 579–596.
11. Pavlenko E.Yu. [Study of the Impact of Attacks on Structural and Parametric Metrics of Networks with Adaptive Topology]. Voprosy kiberbezopasnosti – Cybersecurity Issues. 2023. no. 4(56). pp. 65–71. (In Russ.).
12. Waseem Anwar R., Ali S. Smart Cities Security Threat Landscape: A Review. Computing and Informatics. 2022. vol. 41. pp. 405–423.
13. Kwon H.J., Salim M.M., Park J.H. Recent Trends on Smart City Security: A Comprehensive Overview. Journal of Information Processing Systems. 2023. vol. 19(1). pp. 118–129. DOI: 10.3745/JIPS.03.0182.
14. Telo J. Smart City Security Threats and Countermeasures in the Context of Emerging Technologies. Journal of Intelligent Automation and Computing. 2023. vol. 6. no. 1. pp. 31–45.
15. Ljul'chenko A.N. [Expert system for assessing the effectiveness of information security]. Zashhita Informacii. Insajd – Information Security. Inside. 2016. no. 4. pp. 20–24. (In Russ.).
16. Evdokimov O.G., Gavdan G.P., Reznichenko S.A. [An approach to assessing the effectiveness of the information security system of a distributed data transmission system]. Bezopasnost' informacionnyh tehnologij – Information Technology Security. 2022. vol. 29. no. 2. pp. 57–70. (In Russ.).
17. Anisimov E.G., Anisimov V.G., Gar'kushev A.Ju., Selivanov A.A. [Performance indicators of interdepartmental information interaction in the management of national defense]. Voprosy oboronnnoj tekhniki. Serija 16: Tehnicheskie sredstva protivodejstvija terrorizmu – Defense Technology Issues. Series 16: Technical Counterterrorism Equipment. 2016. no. 7-8(97-98). pp. 12–16. (In Russ.).
18. Drovnikova I., Meshherjakova T., Popov A., Rogozin E., Sitnik S. [Mathematical model for estimating the efficiency of information security systems by means of Laplace transformation and Givens method]. SPIIRAS Proceedings. 2017. vol. 52. no. 3. pp. 234–258. DOI: 10.15622/sp.52.11. (In Russ.).
19. Borovkov V.E., Kljucharev P.G., Denisenko D.I. [Methodology for assessing the performance of web backdoor detection systems]. Informatics and automation. 2025. vol. 24. no. 1. pp. 125–162. DOI: 10.15622/ia.24.1.6. (In Russ.).
20. Bokova O.I., Drovnikova I.G., Etepnev A.S., Rogozin E.A., Hvostov V.A. [Methods for assessing the reliability of information protection systems against unauthorized

- access in automated systems]. SPIIRAS Proceedings. 2019. vol. 18. no. 6. pp. 1301–1332. DOI: 10.15622/sp.2019.18.6.1301-1332. (In Russ.).
21. Trapeznikov E.V. [Algorithm for assessing the security of an information system based on a neural network]. Izvestija Tul'skogo gosudarstvennogo universiteta. Tehnicheskie nauki – News of Tula State University. Technical Sciences. 2017. no. 2. pp. 312–318. (In Russ.).
22. Zhang L., Liu Y. Network Security Prediction and Situational Assessment Using Neural Network-based Method. Journal of Cyber Security and Mobility. 2023. vol. 12. no. 4. pp. 547–568. DOI: 10.13052/jcsm2245-1439.1245.
23. Avdoshin A.S. [Evaluation of information system security using fuzzy logic methods]. Vestnik Samarskogo gosudarstvennogo tehnicheskogo universiteta. Serija: Tehnicheskie nauki – Bulletin of Samara State Technical University. Series: Technical Sciences. 2005. no. 32. pp. 191–193. (In Russ.).
24. Minjaev A.A., Krasov A.V. [Methodology for assessing the effectiveness of the information security system of geographically distributed information systems]. Vestnik Sankt-Peterburgskogo gosudarstvennogo universiteta tehnologii i dizajna. Serija 1: Estestvennye i tehnicheskie nauki – Bulletin of the Saint Petersburg State University of Technology and Design. Series 1: Natural and Technical Sciences. 2020. no. 3. pp. 26–32. (In Russ.).
25. Atlam H.F., Walters R.J., Wills G.B., Daniel J. Fuzzy Logic with Expert Judgment to Implement an Adaptive Risk-Based Access Control Model for IoT. Mobile Networks and Applications. 2021. vol. 26. pp. 2545–2557. DOI: 10.1007/s11036-019-01214-w.
26. Kosmacheva I.M., Davidjuk N.V., Sibikina I.V., Kuchin I.Ju. [Model for assessing the efficiency of information security system configuration based on genetic algorithms]. Modelirovanie, optimizacija i informacionnye tehnologii – Modeling, optimization and information technologies. 2020. vol. 8. no. 3. DOI: 10.26102/2310-6018/2020.30.3.022. (In Russ.).
27. Kotenko I.V., Parashhuk I.B. [Features of operational assessment of the security of critical resources based on adaptive neural network filtering]. Vestnik Astrahanskogo gosudarstvennogo tehnicheskogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika i informatika – Bulletin of the Astrakhan State Technical University. Series: Control, Computer Technics and Informatics. 2023. no. 3. pp. 55–64. (In Russ.).
28. Kotenko I.V., Stepashkin M.V., Kotenko D.I., Dojnikova E.V. [Evaluation of the security of information systems based on the construction of trees of social engineering attacks]. Izvestija vysshih uchebnyh zavedenij. Priborostroenie – News of higher educational institutions. Instrument engineering. 2011. vol. 54. no. 12. pp. 5–9. (In Russ.).
29. Ismagilova A.S., Shagapov I.A., Salov I.V. [Graph-theoretic interpretation of information security system]. Inzhenernyj vestnik Dona – Engineering Bulletin of the Don. 2024. no. 9. pp. 171–179. (In Russ.).
30. Kozlenko A.V., Avramenko V.S., Saenko I.B., Kij A.V. [Method of assessing the level of information protection against unauthorized access in computer networks on the basis of the security graph]. SPIIRAS Proceedings. 2012. vol. 21. no. 2. pp. 41–55. DOI: 10.15622/sp.21.3. (In Russ.).
31. Jazov Ju.K., Avsent'ev O.S., Rubcova I.O. [On the issue of assessing the effectiveness of information protection in electronic document management systems]. Voprosy kiberbezopasnosti – Cybersecurity Issues. 2019. no. 1(29). pp. 25–34. (In Russ.).
32. Gorohova V.F. [Optimizing the Choice of Defenses against Attacks Using Absorbing Markov Chains]. Materialy IV Vserossijskoj nauchno-prakticheskoy konferencii s mezhdunarodnym uchastiem. Omskij gosudarstvennyj tehnicheskij universitet «Sistemy upravlenija, informacionnye tehnologii i matematicheskoe modelirovanie» [Proceedings of the IV All-Russian scientific-practical conference with international

- participation. Omsk State Technical University «Control systems, information technologies and mathematical modeling». 2022. pp. 126–134. (In Russ.).
33. Kolmogorov A.N. [Qualitative study of mathematical models of population dynamics]. Problemy kibernetiki – Problems of cybernetics. 1972. vol. 5. no. 2. pp. 101–106. (In Russ.).
34. Bazykin A.D. Matematicheskaja biofizika vzaimodejstvujushhih populacij [Mathematical biophysics of interacting populations]. USSR Academy of Sciences, Research Computing Center. Moscow: Nauka, 1985. 181 p. (In Russ.).
35. Titov V.A., Vejnberg R.R. [Analysis of existing dynamic models based on the Lotka-Volterra predator-prey equation system]. Fundamental'nye issledovaniya – Fundamental research. 2016. no. 8-2. pp. 409–413. (In Russ.).
36. Bratus' A.S., Novozhilov A.S., Platonov A.P. Dinamicheskie sistemy i modeli biologii [Dynamic systems and models of biology]. Moscow: Fizmatlit, 2011. 400 p. (In Russ.).
37. Romanov M.F., Fedorov M.P. Matematicheskie modeli v jekologii : Uchebnoe posobie [Mathematical models in ecology: Tutorial]. St. Petersburg: Ivan Fedorov, 2003. 239 p. (In Russ.).
38. Volterra V. Matematicheskaja teorija bor'by za sushhestvovanie [Mathematical theory of the struggle for existence]. Moscow-Izhevsk: Institute of Computer Research, 2004. 288 p. (In Russ.).
39. Bratus' A.S., Meshherin A.S., Novozhilov A.S. [Mathematical models of the interaction of pollution with the environment]. Vestnik MGU. Serija «Vychislitel'naja matematika i kibernetika» – Moscow State University Bulletin. Series "Computational Mathematics and Cybernetics". 2001. vol. 6. (In Russ.).
40. Marchuk G.I. Matematicheskie modeli v immunologii i medicine [Mathematical models in immunology and medicine]. Moscow: Nauka, 1985. (In Russ.).
41. Minaev V.A., Sychev M.P., Vajc E.V., Gracheva Ju.V. [Mathematical model of "predator-prey" in the information security system]. Informacija i bezopasnost' – Information and Security. 2016. vol. 19. no. 3. pp. 397–400. (In Russ.).
42. Kamis N.H., Yassin W., Abdollah M.F., Razak S.F.A., Yogarayan S. Blackhole attacks in internet of things networks: a review. Indonesian Journal of Electrical Engineering and Computer Science. 2023. vol. 30. pp. 1080–1090.
43. Aponte-Novo F.A., Orozco A.L.S., Villanueva-Polanco R., Wightman P. The 51% Attack on Blockchains: A Mining Behavior Study. IEEE Access. 2021. vol. 9. pp. 140549–140564.
44. Kalinin M., Krundyshev V. Security intrusion detection using quantum machine learning techniques. Journal of Computer Virology and Hacking Techniques. 2023. vol. 19. no. 1. pp. 125–136.
45. Krundyshev V., Kalinin M., Zegzhda P. Artificial swarm algorithm for VANET protection against routing attacks. IEEE Industrial Cyber-Physical Systems (ICPS). 2018. pp. 795–800.
46. Vasil'ev O.S., Krundyshev V.M. [Securing Smart City Distributed Ledger Systems Based on a Trust Model] Materiały 34-ї nauchno-tehnicheskoy vserossijskoj konferencii «Metody i tehnicheskie sredstva obespechenija bezopasnosti informacii» [Proceedings of the 34th Scientific and Technical All-Russian Conference «Methods and technical means of ensuring information security»]. 2025. pp. 109–110. (In Russ.).

Krundyshev Vasiliy — Ph.D., Associate Professor, Institute of computer science and cybersecurity, Peter the Great St. Petersburg Polytechnic University. Research interests: methods of artificial intelligence for computer security, security models, security evaluation. The number of publications — 120. vmk@ibks.spbstu.ru; 29, Politekhnicheskaya St., 195251, St. Petersburg, Russia; office phone: +7(812)552-7632.

Kalinin Maxim — Ph.D., Dr.Sci., Professor, Institute of computer science and cybersecurity, Peter the Great St. Petersburg Polytechnic University. Research interests: cyber risk analysis, machine learning for cybersecurity, cyber resiliency, models for cyber-physical system protection. The number of publications — 320. max@ibks.spbstu.ru; 29, Politekhnicheskaya St., 195251, St. Petersburg, Russia; office phone: +7(812)552-7632.

Acknowledgements. The study was supported by a grant from the Russian Science Foundation No. 24-11-20005, <https://rscf.ru/project/24-11-20005/>; grant of St. Petersburg Science Foundation (Agreement No. 24-11-20005 on the regional grant).

A. RAJEEV, RAVIRAJ P.

SPATIOTEMPORAL AND BEHAVIORAL FEATURE-AWARE MODEL WITH XCEPTIONCAPSULE FUSION FOR DEEPFAKE DETECTION

Rajeev A., Raviraj P. Spatiotemporal and Behavioral Feature-Aware Model with XceptionCapsule Fusion for Deepfake Detection.

Abstract. Deepfake detection continues to pose significant challenges, primarily because existing methods often suffer from key limitations, including reliance on individual frame analysis, vulnerability to low-resolution or compressed videos, and inability to capture temporal inconsistencies. Furthermore, traditional face detection techniques frequently fail under challenging conditions such as poor lighting or occlusion, while many models struggle with subtle manipulations due to inadequate feature extraction and overfitting on limited datasets. To address the drawbacks of existing deepfake detection approaches, this research proposes a Face and Motion-Aware Detection Framework that integrates both spatial and temporal information. The framework begins with a preprocessing stage that extracts video frames at a fixed rate to ensure temporal consistency. Facial regions and detailed landmarks are accurately detected using BlazeFace and MediaPipe Face Mesh. These features are then processed by the proposed XceptionCapsule Net, which combines the spatial feature extraction capabilities of the Xception model with the hierarchical and viewpoint-aware representation of Capsule Networks (CapsNet), and the temporal dependency modeling power of a Bidirectional Long Short-Term Memory (BiLSTM) layer. The architecture incorporates Global Average Pooling, Flatten, and fully connected layers, with Sigmoid activation for binary classification. Extensive evaluations on the FaceForensics++ (FF++) and Celeb-DF datasets demonstrate strong performance, achieving up to 99.31% accuracy and 99.99% Area Under the Curve (AUC). The results validate the framework's effectiveness, precision, and generalization across various video qualities and manipulation scenarios.

Keywords: deepfake detection, XceptionCapsule Net, Face Mesh, BlazeFace, facial landmark extraction, video forensics.

1. Introduction. The human face is one of the most defining features of an individual, making it a critical component in identity recognition systems [1]. As facial recognition technologies continue to evolve, so do concerns regarding their misuse, particularly with the rapid advancement of facial synthesis techniques. Among the most concerning developments is deepfake technology, an artificial intelligence-driven method that enables the seamless manipulation of facial features. This technology allows a person's face to be superimposed onto another's individual in a video without consent, raising serious ethical, legal, and security concerns. Deepfakes pose serious threats as they can be exploited to spread misrepresentation, steal identities, and carry out harmful activities [2, 3].

Deepfake content, typically in the form of synthetic videos and images, is widely disseminated across social media platforms. Although digital image manipulation has existed since the early days of photography [4], it traditionally required significant expertise and manual

effort, often involving software such as Adobe Photoshop. In contrast, the advent of Artificial intelligence (AI)-based tools has democratized content manipulation. With minimal technical knowledge, users can now generate highly realistic fake videos, making face-swapping and fabricated scenarios appear convincingly authentic [5 – 7].

Deepfake videos are typically generated using machine learning algorithms that digitally alter a subject's appearance by replacing it with that of another individual. These alterations are typically grouped into three main categories:

Head Puppetry: Synchronizes the head and shoulder movements of the target with those of a source individual.

Face Swapping: Replaces one person's face with another while maintaining the original expressions.

Lip-Syncing: Alters lip movements to match audio content not originally spoken by the subject [6].

While traditional computer graphics methods have been employed for similar purposes, modern deepfake generation predominantly relies on deep learning (DL) techniques, including generative adversarial networks (GANs) and autoencoders, which significantly enhance the realism of synthetic media and complicate detection efforts [7, 8]. In addition to these, diffusion-based generative models have recently gained prominence in content synthesis. Models such as Stable Diffusion [9], DALL-E [10], MidJourney [11], and Sora [12] can generate or manipulate highly realistic images and videos from simple textual prompts. By progressively denoising random noise into coherent outputs, these models offer unprecedented control and realism, making synthetic media creation more accessible and further intensifying the challenges of deepfake detection [13, 14]. Recent studies report a substantial increase in deepfake content across digital platforms, intensifying concerns around fraud, misinformation, and privacy violations. To address this challenge, leading organizations such as Defense Advanced Research Projects Agency (DARPA), Facebook, and Google have launched initiatives focused on developing advanced deepfake detection technologies [15, 16]. Numerous DL-based approaches have emerged to address this threat. Techniques involving Long Short-Term Memory (LSTM) networks, Recurrent Neural Networks (RNNs), and hybrid models have shown promise in identifying manipulated media. Additionally, Deep Neural Networks (DNNs) have shown effectiveness in detecting fake news and misleading social media content [17, 18].

However, significant research gaps persist. A major limitation of many current models is their reliance on individual frame analysis, which ignores temporal inconsistencies such as unnatural head movements and

facial expressions. This highlights the importance of temporal modeling through RNNs, LSTMs, or transformer-based architectures to better understand sequential patterns in videos. Additionally, existing systems struggle with low-resolution or compressed videos, where common artifacts are masked, hindering manipulation detection. Face detection, a crucial preprocessing step, is especially vulnerable under real-world conditions, such as occlusion, poor lighting, and low resolution, often resulting in missed or inaccurate face localization. Moreover, as deepfake generation grows more sophisticated, many subtle alterations bypass detection due to the limited feature extraction capabilities of traditional models. Another pressing issue is overfitting, primarily driven by scarce and homogeneous training datasets, which undermines model generalization across diverse manipulation types and datasets. These challenges underscore the urgent need for a versatile, temporally aware, and generalizable deepfake detection framework that can operate effectively under a variety of media conditions and evolving manipulation techniques. To bridge these gaps, this study presents a face and motion-aware framework that effectively utilizes spatial and temporal information to achieve reliable and high-accuracy deepfake detection. The primary contributions are as follows:

1. An innovative framework designed to improve the accuracy and reliability of deepfake detection by combining spatial and temporal feature analysis.
2. The framework ensures consistent frame extraction at a fixed sampling rate to maintain video-level coherence. It utilizes BlazeFace [19] for efficient face localization and landmark detection, along with MediaPipe Face Mesh [20], to provide accurate spatial inputs under challenging conditions such as low resolution, occlusion, and lighting variations.
3. A hybrid deep neural network (DNN) is designed by integrating the Xception model [21] with Capsule Networks (CapsNet) [22] to capture spatial hierarchies and viewpoint variations. This architecture enhances sensitivity to fine-grained facial anomalies and improves generalization across different manipulation types.
4. Temporal dependency modeling is introduced through a Bidirectional Long Short-Term Memory (BiLSTM) layer, which captures sequential relationships and motion continuity between consecutive frames. This addition allows the model to detect temporal inconsistencies in blinking, lip movement, and head motion that are commonly present in manipulated videos.
5. The model employs Global Average Pooling (GAP), followed by Flatten and fully connected layers, with sigmoid activation to ensure robust binary classification.

This article is structured to offer a thorough and organized explanation of the proposed deepfake detection approach. Section 2 reviews relevant literature, outlining existing methods, notable contributions, and existing research gaps in deepfake detection. Section 3 explains the proposed approach in detail, covering the preprocessing steps, extraction of spatial and temporal features, and the overall architecture of the detection model. Section 4 presents the experimental setup and results, accompanied by a detailed performance evaluation using standard benchmark datasets. Finally, Section 5 summarizes the main outcomes and discusses potential future improvements to enhance the effectiveness, adaptability, and reliability of deepfake detection systems.

2. Literature Review. The rapid progress in deepfake generation technologies in recent years has raised serious concerns about the credibility and authenticity of digital content. In response, a range of DL-based detection approaches have been proposed, aiming to accurately differentiate authentic content from manipulated media. Existing literature explores various strategies, including hybrid models, attention mechanisms, and temporal analysis, to address the limitations of earlier frame-level or spatial-only methods. These efforts underscore the urgent need for robust, generalizable frameworks capable of detecting subtle visual and temporal inconsistencies across diverse datasets and manipulation techniques.

In paper [23] the authors introduced a novel approach to deepfake detection by analyzing the contribution of distinct facial regions using face cutout techniques. This study was included in our review because it addresses the overfitting problem in deepfake datasets and aligns with the emerging trend of leveraging facial region importance for more robust detection. Input images were augmented by selectively removing facial areas based on landmarks, creating diverse training samples, while training was conducted with an 80/10/10 split for training, validation, and testing. The methodology was evaluated on FF++ and Celeb-DFv2 datasets, achieving up to 91% accuracy on Celeb-DF and demonstrating the significance of external facial features, particularly the eyes, for detection. This work highlights a broader trend in deepfake research toward targeted data augmentation strategies and feature-aware model training, though it suggests further exploration is needed for video-based deepfake detection and cross-dataset generalization.

Paper [24] proposed a Frequency-Enhanced Self-Blended Images (FSBI) approach for deepfake detection, which blends images with themselves to introduce generic forgery artifacts and uses Discrete Wavelet Transform (DWT) to extract discriminative frequency-domain features. This study was included in our review because it demonstrates a trend

toward frequency-aware and artifact-generalized detection strategies that improve model robustness and cross-dataset generalization. The model was evaluated on FF++ and Celeb-DF datasets using both within-dataset and cross-dataset protocols, achieving an AUC of 95.49% when trained on FF++ and tested on Celeb-DF, highlighting strong adaptability to unseen manipulations. FSBI effectively mitigates overfitting to dataset-specific artifacts, and ablation studies confirmed the benefits of self-blending and frequency feature extraction. This work illustrates the broader research trend of combining spatial and frequency-domain analysis for deepfake detection, though performance remains lower for certain complex manipulations such as NeuralTextures (NT) and Face2Face (F2F), suggesting areas for further improvement in real-world scenarios.

In paper [25] the authors proposed an efficient deepfake detection framework using a hybrid ResNet-Swish-BiLSTM network, which combines residual learning for spatial features with recurrent modeling of temporal dependencies. The model was extensively tested on the FaceForensics++ (FF++) and Deepfake Detection Challenge (DFDC) datasets, achieving 96.23% accuracy on FF++ and 78.33% accuracy when aggregating FF++ and DFDC records. To assess generalization, they further conducted cross-corpus experiments using Celeb-DF, where performance dropped to AUC values of 71.56% (DFDC) and 70.04% (Celeb-DF) when trained on FF++, and 70.12% (FF++) and 65.23% (Celeb-DF) when trained on DFDC. This evaluation highlights a broader trend in deepfake detection research: models often perform well in database-internal evaluations but degrade under cross-dataset conditions due to differences in compression, resolution, and manipulation artifacts. The study was included in our review as it illustrates both the strength of hybrid spatial-temporal learning and the persistent challenge of cross-dataset generalization, which directly relates to our proposed approach.

Paper [26] introduced a deepfake detection framework, BMNet, that integrates BiLSTM to capture temporal dependencies across frames and multi-head self-attention (MHSA) to extract localized forgery features from facial regions. Unlike static CNN-based methods, BMNet explicitly models both temporal and regional inconsistencies, addressing a key gap in prior research. The model was evaluated on four benchmark datasets (FF++, UADFV, Celeb-DF, DFDC) and achieved 95.54%, 92.18%, 80.20%, and 84.72% accuracy, respectively, demonstrating consistent improvements across varying data sources. Importantly, the inclusion of landmark-based features enhanced interpretability and robustness, with ablation studies confirming the contribution of both BiLSTM and MHSA modules. This work was included in our survey because it exemplifies a spatiotemporal

trend in deepfake detection and shows stronger cross-dataset adaptability than handcrafted or purely spatial CNN models, while still highlighting the persistent performance gap on Celeb-DF compared to easier datasets.

In [27] the authors introduced a stacking-based ensemble framework that fuses deep features from Xception and EfficientNet-B7, followed by feature ranking and classification using an MLP meta-learner. The model achieved 96.33% accuracy on Celeb-DF (V2) and 98.00% on FaceForensics++ (FF++), outperforming the individual base models. Their experimental setup used clear train/validation/test splits for both datasets, ensuring fair evaluation and reproducibility. This work was selected as it represents the ensemble and meta-learning trend in deepfake detection, focusing on combining complementary deep models with feature selection for improved robustness. However, the authors also noted limitations, including increased computational cost, reduced interpretability, and potential overfitting risks, issues that remain common across ensemble approaches. The study is significant because it demonstrates how carefully designed stacking can improve cross-dataset generalization, while also highlighting challenges in balancing accuracy with efficiency and transparency.

Paper [28] introduced a self-supervised BEiT-HPR (Hierarchical PatchReducer) model for efficient facial deepfake detection aimed at addressing the high computational cost associated with existing detection systems. The study was motivated by the growing difficulty of distinguishing real from fake facial videos due to the rapid advancement of generative models and the impracticality of deploying complex models in resource-limited environments. Experimental results across FF++, Celeb-DF, and DFD datasets demonstrated notable efficiency gains and strong detection performance. However, the approach may face limitations in handling unseen forgery types or cross-dataset generalization due to its reliance on self-supervised pretraining within limited data domains.

In paper [29] the authors proposed ConvNext-PNet, an interpretable and explainable deep learning framework for detecting visual deepfakes, aiming to enhance trust and transparency in AI-based forgery detection. The motivation behind this work was to address the limitation of existing deepfake detection models that, despite achieving high accuracy, lack interpretability and fail to justify their classification decisions. By integrating prototype learning into a modified ConvNext architecture, the model not only improves discriminative feature learning but also provides visual reasoning for its predictions, thereby increasing user trust. Experimental evaluations on benchmark datasets such as FF++, CelebDF, DFDC-P, and DFF demonstrated high robustness and effective detection of

visual manipulations. However, the added interpretability components may introduce additional computational overhead, potentially limiting real-time applicability in large-scale or streaming scenarios.

In [30] the authors introduced an improved deepfake video detection framework based on a Convolutional Vision Transformer (CViT2) that combines the strengths of CNNs and Vision Transformers to enhance detection accuracy and generalization. The model was proposed to address the limitations of existing CNN-based methods, which often struggle to capture global dependencies and contextual information in video frames. By employing a CNN for extracting learnable spatial features and a Vision Transformer for modeling long-range relationships using attention mechanisms, the CViT2 architecture effectively identifies subtle manipulation cues in deepfake videos. Experiments conducted across multiple benchmark datasets, including DFDC, FF++, Celeb-DF v2, and DeepfakeTIMIT, demonstrated high accuracy and strong cross-dataset robustness. However, the model's complex structure and heavy training requirements may restrict its real-time applicability and scalability in low-resource environments.

Paper [31] proposed a robust face forgery detection framework that integrates both local and global texture information to enhance detection accuracy and generalization. The method was introduced to address the limitations of existing CNN-based approaches, which often overfit training data and fail to capture subtle forgery traces across diverse sources and post-processing variations. By employing a two-stream architecture combining RGB and texture features, along with an adaptive feature fusion and attention mechanism, the model effectively exposes fine-grained artifacts at multiple scales. This approach improves robustness and feature discrimination, leading to better performance across benchmark datasets. However, the model's complexity and computational cost may limit its deployment in real-time or resource-constrained environments.

Paper [32] proposed a hybrid CNN-LSTM model for video deepfake detection that leverages optical flow features to capture both spatial and temporal cues from video frames. The approach was introduced to overcome the limitation of conventional CNN-based methods, which primarily focus on spatial information and fail to exploit temporal dependencies between frames. This hybrid strategy enhances detection accuracy even with a limited number of samples, achieving competitive results on benchmark datasets such as DFDC, FF++, and Celeb-DF. However, the model's performance may still be constrained by moderate accuracy on challenging datasets and dependence on precise optical flow computation, which can increase computational overhead.

These studies highlight the evolving sophistication of deepfake detection frameworks and the need to incorporate spatial, temporal, and attention-based mechanisms. Nonetheless, existing methods often fail to address issues such as generalization [27] to unseen manipulations, real-world distortions, and computational efficiency. Table 1 offers a detailed overview of the main insights and approaches highlighted in the literature review.

Table 1. Overview of the literature review

No.	Methodology	Key Features	Dataset & Split	Performance	Limitations / Observations
[23]	Face cutout-based augmentation	Region-specific face removal; data augmentation to reduce overfitting	FF++, Celeb-DFv2; 80/10/10 train/val/test	91% on Celeb-DF	Eyes most impactful; limited exploration for video sequences & cross-dataset validation
[24]	FSBI (Frequency Enhanced Self-Blended Images) + DWT	Self-blended images to create generic artifacts; frequency domain features	FF++, Celeb-DF; within- and cross-dataset	AUC 95.49% (FF++→Celeb-DF)	Lower performance on complex manipulations (F2F, NT); needs real-world evaluation
[25]	ResNet-Swish-BiLSTM hybrid	Residual CNN for spatial + BiLSTM for temporal modeling	FF++, DFDC, Celeb-DF; cross-corpus evaluation	96.23% (FF++), 78.33% (FF++DFDC); AUC 70-71% cross-dataset	Strong intra-dataset performance, weak cross-dataset generalization
[26]	BMNet (BiLSTM + MHSA)	Temporal + regional attention; landmark-based features	FF++, UADFV, Celeb-DF, DFDC	95.54%, 92.18%, 80.20%, 84.72%	Cross-dataset gap on Celeb-DF; highlights spatiotemporal trend
[27]	Stacking ensemble (Xception + EfficientNet-B7 + MLP)	Feature fusion + meta-learning; deep feature ranking	FF++, Celeb-DFv2; clear train/val/test split	98% (FF++), 96.33% (Celeb-DFv2)	Increased computation; interpretability issues; risk of overfitting

Continuation of the Table 1

No.	Methodology	Key Features	Dataset & Split	Performance	Limitations / Observations
[28]	Self-Supervised BEiT-HPR (Hierarchical PatchReducer)	Hierarchical patch reduction to lower computation; self-supervised BEiT backbone	FF++, Celeb-DF, DFD; standard benchmark split	83.92% (FF++), 97.59% (Celeb-DF), 98.25% (DFD)	Strong accuracy with reduced complexity; may face limitations on unseen forgery types
[29]	ConvNext-PNet (Prototype-based ConvNext)	Prototype learning for interpretability; explainable visual reasoning	FF++, CelebDF, DFDC-P, DFF	High robustness across datasets (specific accuracy not stated)	Provides interpretability; adds computational overhead affecting real-time use
[30]	Convolutional Vision Transformer (CViT2)	CNN for spatial extraction + ViT for global context with attention	DFDC, FF++, Celeb-DFv2, DeepfakeTIMIT, TrustedMedia	95% (DFDC), 94.8% (FF++), 98.3% (Celeb-DFv2), 76.7% (TIMIT)	Excellent cross-dataset accuracy; high model complexity and training cost
[31]	Two-stream texture-aware network	Integration of global and local texture features; adaptive fusion and attention modules	Multiple benchmark datasets (FF++, Celeb-DF, etc.)	Outperformed recent SOTA methods	High computational complexity; limited real-time applicability
[32]	Hybrid CNN-LSTM with optical flow	Temporal feature extraction via optical flow; hybrid spatial-temporal learning	DFDC, FF++, Celeb-DF; ≤ 100 frames/sample	66.26% (DFDC), 91.21% (FF++), 79.49% (Celeb-DF)	Moderate accuracy on complex datasets; relies on precise optical flow computation

A comprehensive review of recent studies reveals several key trends and research directions in the domain of deepfake detection. Contemporary approaches increasingly emphasize spatial-temporal integration, where models such as those in [25 – 27, 30, 32] combine spatial and temporal features to overcome the limitations of static frame analysis. Techniques incorporating BiLSTM or hybrid CNN-LSTM frameworks have demonstrated the ability to capture motion inconsistencies across consecutive frames, thereby improving temporal awareness and detection accuracy. Another significant development is the adoption of attention-based and

transformer-based mechanisms, as observed in BMNet [26], CViT2 [30], and GRAM [31], which capture global relationships and multi-scale feature dependencies to achieve better generalization across diverse datasets. Furthermore, frequency and artifact-based analysis methods, including DWT and FSBI [24], have proven effective in identifying high-frequency inconsistencies that are often imperceptible in RGB domains. Researchers have also explored ensemble and meta-learning strategies [27, 31], where complementary features from CNN and transformer architectures are fused to enhance stability and robustness, albeit at increased computational cost. In parallel, there is growing attention toward explainable and efficient detection models [28, 29], which ensure interpretability and real-time applicability – key requirements for deployment in social media monitoring and law enforcement systems. Despite these advancements, a persistent cross-dataset generalization gap remains a major challenge, as many models still exhibit significant performance degradation when evaluated on unseen data [25, 27]. Overall, the literature reflects a clear evolution from static, handcrafted models toward dynamic, spatial-temporal, and attention-driven architectures, with a heightened emphasis on explainability, efficiency, and adaptability. Building on these emerging trends, the proposed research introduces a unified Face and Motion-Aware XceptionCapsule Net that synergistically integrates spatial and temporal cues to achieve enhanced robustness and reliability in detecting diverse deepfake manipulations.

3. Proposed methodology. Existing deepfake detection models encounter several critical challenges that significantly impact their accuracy and robustness [23, 24]. A primary limitation is their reliance on individual frame analysis, which performs inadequately on low-resolution or highly compressed videos where visual artifacts such as blurring and pixelation are less perceptible [25, 26]. This diminishes the model’s effectiveness in identifying manipulated content. Furthermore, face detection in such models is highly sensitive to environmental factors, including poor lighting, occlusions, and extreme facial angles, often resulting in missed or inaccurate face localizations [27, 28]. Another key limitation lies in the disregard of temporal inconsistencies. Since many models process frames independently, they fail to capture unnatural head movements or inconsistent facial expressions that may indicate tampering [29, 30]. As deepfake generation techniques become increasingly sophisticated, subtle manipulations with minimal visual cues often go undetected due to inadequate feature extraction mechanisms [21]. Additionally, many models suffer from overfitting, primarily caused by limited and homogeneous training data, thereby restricting their generalization to unseen deepfake formats and real-world media conditions [33, 34].

To overcome these drawbacks, this work proposes an innovative Face and Motion-Aware Detection Framework. The preprocessing step enhances temporal consistency by extracting video frames at a uniform frame rate. For face detection, the framework employs BlazeFace, which enables efficient and accurate facial region extraction. Subsequently, MediaPipe Face Mesh is used to extract detailed 3D facial landmarks, improving the granularity of spatial feature identification. The extracted features are then fed into the proposed XceptionCapsule-BiLSTM Net, which integrates the Xception network, CapsNet, and a Bidirectional Long Short-Term Memory (BiLSTM) layer to jointly capture spatial details and temporal dependencies. The Xception module, utilizing depthwise separable convolutions, is effective at extracting fine-grained spatial features that are critical for identifying deepfake artifacts. In parallel, the CapsNet component preserves spatial hierarchies and models the interrelationships between features, while the BiLSTM layer captures sequential frame relationships and motion dynamics, enabling the detection of temporal anomalies such as unnatural motion or facial distortions. The model architecture incorporates Global Average Pooling (GAP) to reduce dimensionality, a Flatten layer to vectorize the features, and Fully Connected layers to extract high-level representations. A Sigmoid activation function is used for binary classification between real and fake content. The strength of this approach lies in its unified spatial-temporal modeling via the XceptionCapsule-BiLSTM Net, which enhances the detection of subtle manipulations and improves robustness against common real-world challenges such as low resolution, compression artifacts, and sophisticated forgery techniques. Experimental evaluations (see Section 4) confirm the efficacy and generalizability of the proposed approach on multiple benchmark datasets. Figure 1 illustrates the block diagram of the proposed deepfake detection methodology.

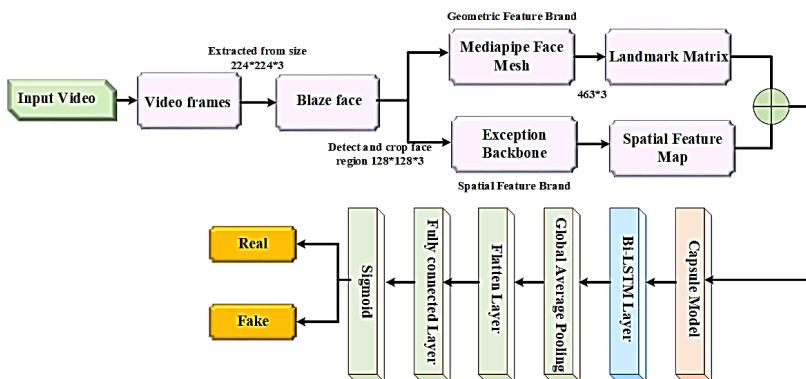


Fig. 1. Block diagram of the proposed methodology

3.1. Preprocessing: BlazeFace Mesh Processor. The preprocessing stage plays a crucial role in enhancing deepfake detection, especially when dealing with low-resolution or highly compressed video inputs. Such conditions often obscure subtle artifacts and degrade the accuracy of face detection, particularly under poor lighting, occlusions, or low image quality. To overcome these drawbacks, this work introduces a novel BlazeFace Mesh Processor, designed to ensure robust and consistent facial region extraction. Initially, input videos are decomposed into individual frames at a uniform frame rate, thereby preserving temporal coherence essential for detecting sequential anomalies. The BlazeFace model is then employed to perform fast and efficient face detection, generating precise bounding boxes for each detected face within the frames. Subsequently, MediaPipe Face Mesh is applied to these detected faces to extract dense 3D facial landmarks. This step significantly enhances the granularity of spatial feature representation, improving the identification of subtle facial deformations introduced by deepfake manipulations. The integration of BlazeFace and MediaPipe in a unified pipeline ensures both speed and precision in preprocessing, laying a strong foundation for effective feature extraction and subsequent deepfake detection.

3.1.1. Video Frames. Video frames are the basic units for analyzing spatial and temporal features in deepfake detection. A video is first converted into individual frames at a consistent frame rate (typically 30 fps) to preserve temporal coherence, allowing the framework to detect anomalies such as unnatural facial expressions, inconsistent head movements, or temporal flickering. Each frame is then processed using the BlazeFace model, which accurately localizes faces by generating precise bounding boxes, providing a reliable foundation for subsequent manipulation detection.

3.1.2. BlazeFace. To accurately isolate face regions from individual video frames, the proposed framework employs BlazeFace, a real-time neural network-based face detector optimized for mobile and embedded Graphics Processing Units (GPUs). It is designed to deliver high inference speeds while maintaining accurate face localization and keypoint estimation. This makes it well-suited for handling extensive video datasets in deepfake detection applications.

BlazeFace uses depthwise separable convolution with 5×5 kernels to achieve a larger receptive field at low computational cost. The network architecture is built using BlazeBlocks and Double BlazeBlocks, which preserve spatial resolution while minimizing computational overhead. The model operates on input frames of size $128 \times 128 \times 3$, and outputs both

bounding boxes and six key facial landmarks, including positions of the eyes, nose, ears, and mouth center. Specifically, the output tensors are:

- **Bounding boxes:** $[N, 4]$, where N is the number of faces detected, and 4 represents the coordinates $(x_{min}, y_{min}, x_{max}, y_{max})$ of each face.
- **Facial landmarks:** $[N, 6, 2]$, where 6 corresponds to the six keypoints and 2 represents (x, y) coordinates normalized relative to the input frame.

Figure 2 illustrates the structure of the BlazeBlock and Double BlazeBlock components.

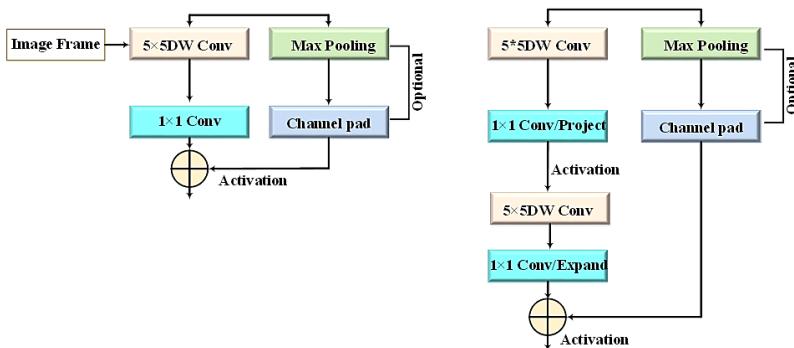


Fig. 2. Structure of BlazeBlock and Double BlazeBlock

Let $I \in \mathbb{R}^{H \times W \times 3}$ denote an input video frame. The model generates a set of anchor boxes $\{a_k\}_{k=1}^K$. For each anchor, the network predicts:

Bounding box offsets:

$$(\Delta x_k, \Delta y_k, \Delta w_k, \Delta h_k), \quad (1)$$

where Δx_k denotes the horizontal offset of the bounding box center for anchor k ; Δy_k denotes the vertical offset of the bounding box center for anchor k ; Δw_k denotes the logarithmic scaling factor for the width of bounding box k ; Δh_k denotes logarithmic scaling factor for the height of bounding box k ; k represents the index of the anchor box among total anchors.

Keypoint coordinates:

$$\{P_{ki}\}_{i=1}^6 \in \mathbb{R}^2, \quad (2)$$

where P_{ki} denotes the 2D coordinate (x, y) of the i^{th} facial landmark for anchor k ; and \mathbb{R}^2 indicates each key point represented in 2D space.

The final bounding box b_k is computed as:

$$x'_k = x_k^a + \Delta x_k \cdot w_k^a, \quad y'_k = y_k^a + \Delta y_k \cdot h_k^a, \quad (3)$$

where x'_k and y'_k denote the refined center coordinates of bounding box k ; x_k^a and y_k^a denote the anchor box center coordinates for anchor k ; w_k^a and h_k^a denote the anchor box width and height; and Δx_k and Δy_k denote the predicted offsets.

$$w'_k = w_k^a \cdot \exp(\Delta w_k), \quad h'_k = h_k^a \cdot \exp(\Delta h_k), \quad (4)$$

where w'_k and h'_k denote the refined width and height of bounding box k ; w_k^a and h_k^a denote the anchor width and height; Δw_k and Δh_k predicted scaling factors; and $\exp(\cdot)$ denotes the exponential function to ensure positive dimensions.

The facial keypoints are then computed as:

$$P'_{ki} = P_{ki} \cdot (w'_k, h'_k) + (x'_k, y'_k), \quad (5)$$

where P'_{ki} denotes the refined location of landmark i for anchor k ; P_{ki} represent the normalized keypoint coordinates; (w'_k, h'_k) represent the bounding box size; and (x'_k, y'_k) represent the bounding box center.

To reduce temporal jitter across frames, a common artifact in deepfake content, BlazeFace implements a weighted blending strategy in place of traditional Non-Maximum Suppression (NMS). The final refined bounding box is computed as:

$$b_{final} = \frac{\sum_{k \in N} w_k \cdot b_k}{\sum_{k \in N} w_k}, \quad (6)$$

where w_k is the confidence score; b_{final} denotes the final bounding box after blending; and N is the set of overlapping anchor boxes. This enhances frame-to-frame consistency, helping the model distinguish genuine manipulations from jitter-induced artifacts, thereby increasing the reliability of detection.

3.1.3. MediaPipe Face Mesh. After detecting the face regions using BlazeFace, the framework integrates MediaPipe Face Mesh to extract a dense set of 3D facial landmarks. This enables the detection of unnatural

facial geometry and behavioral inconsistencies, which are often indicative of deepfake manipulations.

MediaPipe Face Mesh predicts a total of 468 3D facial landmarks, represented as:

$$L = \{(x_i, y_i, z)\}_{i=1}^{468} \in \mathbb{R}^{468 \times 3}, \quad (7)$$

where L denotes the set of 3D landmark coordinates; and x_i, y_i, z denote the coordinates of landmark i .

These landmarks span the entire facial geometry, including contours, lips, nose, eyes, eyebrows, jawline, and forehead. The input to MediaPipe Face Mesh is the face crop provided by BlazeFace, resized and normalized to a tensor of size $128 \times 128 \times 3$, consistent with the BlazeFace output bounding box region. This normalization removes scale and rotation variances, ensuring consistent landmark extraction across frames. The extracted landmarks are utilized to compute both geometric and behavioral features, which are highly sensitive to subtle facial manipulations introduced by generative adversarial networks (GANs). Several key features derived from these landmarks include:

Eye Aspect Ratio (EAR) for blink analysis:

$$EAR = \frac{||L_2 - L_6|| + ||L_3 - L_5||}{2 \cdot ||L_1 - L_4||}. \quad (8)$$

This ratio helps monitor blinking behavior and can reveal synthetic inconsistencies.

Mouth Aspect Ratio (MAR) is used to identify lip-sync anomalies, which are indicative of poor audio-visual alignment in deepfakes.

Facial symmetry deviation is calculated by comparing corresponding landmarks on the left and right sides of the face to assess asymmetry introduced by manipulation.

Temporal displacement of keypoints, which captures jitter or abnormal warping across consecutive frames, is a common artifact in manipulated videos.

The combined BlazeFace + MediaPipe Face Mesh pipeline establishes a robust preprocessing foundation by ensuring precise face localization and dense landmark tracking, even under adverse conditions such as low lighting, occlusion, or blurred resolution. By analyzing temporal coherence across frames, the framework detects subtle geometric distortions, expression inconsistencies, and behavioral anomalies, traits

rarely found in authentic content. Furthermore, it supports high-resolution tracking of facial dynamics, such as eye blinking, lip movement, and overall facial expression behavior, thereby improving deepfake detection reliability.

3.2. XceptionCapsule-BiLSTM Net. Existing deepfake detection models often analyze individual frames, missing temporal cues such as head movements or inconsistent facial expressions, which limits their performance on subtle manipulations. To address this, we propose the XceptionCapsule-BiLSTM Net, a hybrid architecture that processes sequences of N consecutive frames (16 in our experiments) to capture both spatial and temporal dependencies such as eye blinks, lip-syncing, and head motion. The model integrates Xception for high-resolution spatial feature extraction and CapsNet to preserve spatial hierarchies and inter-feature relationships. To further enhance temporal modeling, a BiLSTM layer is incorporated after the Capsule layer. The BiLSTM learns sequential dependencies across consecutive frame embeddings, enabling the network to recognize motion continuity and detect temporal inconsistencies such as abrupt facial transitions or unnatural movements. This addition ensures that the model processes video segments as coherent temporal sequences rather than isolated frames. Key layers include GAP for feature reduction, Flatten and Fully Connected layers for high-level representation, and a Sigmoid activation for binary classification. By combining spatial hierarchy learning (Xception + CapsNet) with temporal dependency modeling (BiLSTM), the proposed architecture significantly enhances robustness, accuracy, and generalization in detecting both obvious and subtle deepfakes in real-world scenarios.

3.2.1. Xception Model. The Xception model is particularly effective for deepfake detection due to its superior capability in spatial feature extraction. Unlike conventional CNNs, which perform standard convolution over both spatial and channel dimensions simultaneously, Xception employs depthwise separable convolutions, dividing the process into two stages: depthwise convolution individually processes each input channel using separate filters, while pointwise convolution uses 1×1 convolutions to merge the results from the depthwise operation. This decomposition results in significant computational efficiency and a reduction in the number of learnable parameters, while still maintaining the capacity to capture essential visual features. In the proposed framework, Xception processes RGB face crops extracted by BlazeFace, with an input tensor of size $128 \times 128 \times 3$. The network outputs feature maps of shape [batch_size, h, w, c], where h, w, and c correspond to the height, width, and number of channels of the final convolutional layer. These feature maps retain rich spatial information, enabling the detection of subtle artifacts introduced by

generative models, such as slight geometric distortions, texture inconsistencies, and skin tone mismatches.

The model's enhanced spatial sensitivity enables it to effectively distinguish authentic faces from manipulated ones, even in high-resolution or minimally altered fake videos. The architectural pipeline of the Xception model is illustrated in Figure 3, showcasing its layered depthwise separable convolutional structure optimized for detailed pattern recognition in facial analysis.

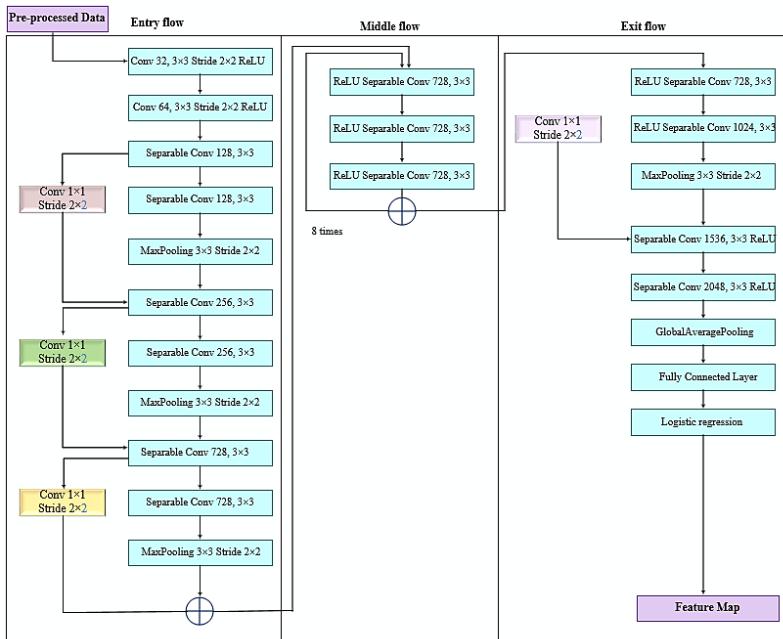


Fig. 3. Architecture of the Xception model

3.2.2. Capsule Model. The CapsNet is designed to overcome the limitations of traditional CNNs, particularly their inability to preserve spatial hierarchies and capture part-whole relationships in visual data. Unlike CNNs, which use scalar activations and pooling operations that often discard spatial information, CapsNet represents features as vectors, thereby encoding both the presence and pose (e.g., position, orientation, deformation) of detected entities.

The core building block of CapsNet is the capsule, a group of neurons whose activity vector $u_i \in \mathbb{R}^d$ encodes the instantiation parameters

of a specific object or object part. Capsules are organized hierarchically such that higher-level capsules model increasingly complex entities by aggregating information from lower-level capsules.

To support this hierarchy, CapsNet introduces a dynamic routing mechanism between layers. Each capsule i in the primary capsule layer predicts the output of capsule j in the next layer using a learned transformation matrix W_{ij} . The predicted output is computed as:

$$\hat{u}_{j|i} = W_{ij}u_i. \quad (9)$$

Here, $\hat{u}_{j|i}$ is the prediction vector from capsule i to capsule j , and u_i is the output vector of capsule i . These predictions are aggregated into a total input S_j for capsule j through a weighted sum of the predictions:

$$S_j = \sum_i c_{ij} \hat{u}_{j|i}. \quad (10)$$

Here, c_{ij} are the coupling coefficients that determine the contribution of capsule i to capsule j , and $\hat{u}_{j|i}$ is the predicted output from capsule i . These coefficients are computed through a routing-by-agreement mechanism, using a softmax function over initial logits b_{ij} , which are iteratively updated:

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})}. \quad (11)$$

The final output of capsule j , denoted v_j , is computed by applying a nonlinear function to S_j . This function ensures that short vectors are shrunk to nearly zero length (representing absence), while longer vectors are scaled to a length slightly below 1 (representing its presence), without affecting their orientation:

$$v_j = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \cdot \frac{s_j}{\|s_j\|^2}, \quad (12)$$

where the length $\|v_j\|$ represents the probability that the entity modeled by capsule j exists, and the direction of v_j encodes its pose and $\|s_j\|$ is the magnitude of input vector. This structure enables CapsNet to retain spatial hierarchies and model complex visual relationships, making it particularly

effective for detecting subtle, hierarchical inconsistencies inherent in deepfake content. The architecture of the CapsNet is illustrated in Figure 4.

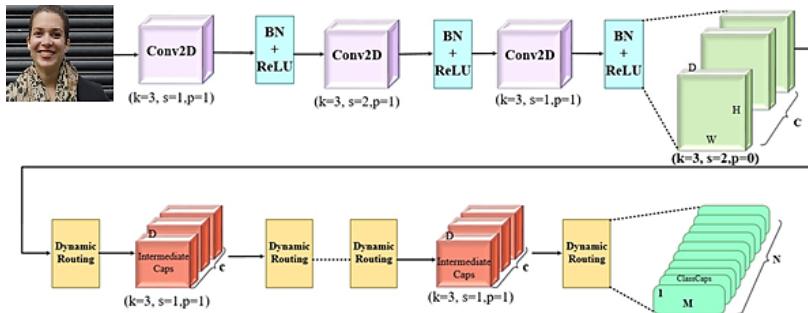


Fig. 4. Structure of CapsNet

This mechanism enables CapsNet to retain detailed spatial relationships and generalize effectively across transformations such as rotation and scaling. Consequently, CapsNet proves particularly effective in tasks requiring precise localization, pose estimation, and structure-preserving representations, such as facial analysis, medical imaging, and deepfake detection. The proposed XceptionCapsule Net architecture integrates the powerful spatial feature extraction capabilities of the Xception network with the hierarchical modeling strength of CapsNet. By leveraging key architectural components such as Global Average Pooling, Flatten, Dense layers, Capsule layers, and a final Sigmoid activation function, the model robustly captures subtle visual artifacts and spatial dependencies. This well-structured design significantly improves the precision and reliability of distinguishing between real and fake videos.

3.2.3. BiLSTM Layer. To capture temporal dependencies across consecutive video frames, a BiLSTM layer is introduced after the Capsule layer. While the Capsule Network effectively models spatial hierarchies and part-whole relationships, it does not account for sequential variations in motion or expression. The BiLSTM addresses this by processing sequential capsule feature embeddings from consecutive frames, learning both forward and backward temporal correlations. This enables the model to capture motion dynamics such as eye blinking, lip movement, and head rotation over time, patterns that are often inconsistent in manipulated content. Mathematically, if v_t represents the capsule output at time t , the BiLSTM learns temporal features as:

$$\vec{h}_t = LSTM_f(v_t, \vec{h}_{t-1}), \quad (13)$$

$$\overleftarrow{h}_t = LSTM_b(v_t, \overrightarrow{h}_{t+1}), \quad (14)$$

$$\overleftarrow{h}_t = [\vec{h}_t; \overleftarrow{h}_t]. \quad (15)$$

This bidirectional formulation allows the model to analyze both past and future contextual dependencies, ensuring a holistic understanding of temporal behavior across frame sequences. The BiLSTM output is subsequently passed to the Global Average Pooling (GAP) layer for dimensionality reduction and further classification processing.

3.2.4. GAP Layer. The GAP layer replaces traditional fully connected layers by computing the average of each feature map in the final convolutional layer. For a feature map $F \in \mathbb{R}^{h \times w}$, GAP is computed as:

$$GAP(F) = \frac{1}{h \cdot w} \sum_{i=1}^h \sum_{j=1}^w F_{ij}, \quad (16)$$

where F denotes the feature map, $h \cdot w$ is the height and width of the feature map, and F_{ij} is the value at pixel (i, j) . This significantly reduces the number of trainable parameters, thereby minimizing overfitting and preserving global contextual information.

3.2.5. Flatten Layer. Following GAP, the flatten layer reshapes the output into a one-dimensional vector. It transforms the tensor from shape $(batch_size, channels, 1, 1)$ into $(batch_size, channels)$, serving as a bridge between convolutional feature extractors and subsequent high-level reasoning layers.

3.2.6. Fully Connected (Dense) Layer. The dense layer functions as a fully connected neural layer, responsible for learning complex feature representations. It performs a linear transformation followed by a non-linear activation:

$$y = f(Wx + b), \quad (17)$$

where x is the input vector, W is the weight matrix, b is the bias vector, and f is an activation function. This layer enhances feature abstraction and captures semantic information crucial for distinguishing deepfakes.

3.2.7. Sigmoid Activation Layer. The final layer employs the sigmoid activation function $\sigma(x)$ for binary classification:

$$\sigma(x) = \frac{1}{1 + e^{-x}}. \quad (18)$$

This produces a probability score $p \in [0,1]$, where: $p \approx 1 \rightarrow \text{real}$, $p \approx 0 \rightarrow \text{likely fake}$.

It is compatible with binary cross-entropy loss, making it ideal for binary classification problems.

Table 2. Input-Output Tensor Flow and Integration with MediaPipe

Stage	Input Tensor	Output Tensor
BlazeFace	$128 \times 128 \times 3$	$[N, 4]$ bounding boxes + $[N, 6, 2]$ keypoints
MediaPipe Face Mesh	$128 \times 128 \times 3$ (face crop)	$[468, 3]$ landmarks
Xception	$128 \times 128 \times 3$	[batch size, h, w, c] feature maps

3.2.8. Fusion of MediaPipe Landmarks with XceptionCapsule Pipeline. The extracted 3D facial landmarks from MediaPipe Face Mesh are used as auxiliary behavioral and geometric features. Each frame's landmark vector $L = [x_1, y_1, z_1, x_2, y_2, z_2, \dots, x_{468}, y_{468}, z_{468}] \in \mathbb{R}^{1404}$ is normalized and concatenated with the high-level spatial features $F_s \in \mathbb{R}^{h \times w \times c}$ obtained from the Xception encoder.

To ensure compatibility in feature space, a linear projection layer $\phi(\cdot)$ maps landmark features into the same latent dimension:

$$F_l = \phi(L) = W_l L + b_l, \quad (19)$$

where $W_l \in \mathbb{R}^{d \times 1404}$ and $b_l \in \mathbb{R}^d$. The projected landmark vector is then fused with the Xception feature tensor using an additive attention-based blending:

$$F_{fusion} = \alpha \cdot F_s + (1 - \alpha) \cdot F_l, \quad (20)$$

where $\alpha \in [0,1]$ controls the contribution of spatial and landmark features, optimized during training. The fused representation F_{fusion} is passed to the CapsNet module, enabling the model to jointly reason about spatial, geometric, and behavioral cues. This process enhances sensitivity to micro-

expressions, eye-blink patterns, and lip-sync deviations that are often missed by frame-only CNNs.

4. Results and Discussion. This section presents the evaluation of the proposed deep learning model for deepfake detection in facial videos. By leveraging spatial and temporal features in facial expressions and movements, the model accurately distinguishes authentic from manipulated content. The approach achieves high detection performance while maintaining interpretability and reliability – essential for real-world applications such as media forensics, digital trust frameworks, and security systems.

4.1. Experimental Setup and Configuration. The proposed deepfake detection framework was implemented in Python 3.10 using Jupyter Notebook. TensorFlow was used for model development and training, while Scikit-learn handled data preprocessing, analysis, and evaluation. Experiments were conducted on a 64-bit Windows 10 system with a 7th-generation Intel Core i7 (2.8 GHz). Datasets were split 80/20 for training and testing, providing a stable platform for evaluating complex architectures such as XceptionCapsule Net.

4.2. Dataset Description.

Dataset 1: FaceForensics++ (FF++): The FF++ dataset [33] serves as a comprehensive and widely adopted benchmark for deepfake detection research. It comprises approximately 1,000 real video samples sourced from YouTube, each containing clear, stable, and front-facing facial recordings suitable for manipulation. From these original videos, over 4,000 manipulated videos were synthesized using four distinct facial manipulation techniques: DeepFakes (autoencoder-based face replacement), FaceSwap (graphics-based replacement), Face2Face (real-time facial reenactment), and NeuralTextures (neural rendering-based synthesis). A notable strength of FF++ is its provision of multiple compression settings, including raw (uncompressed), high-quality (HQ), and low-quality (LQ). This simulates real-world video scenarios, such as those encountered on social media platforms. Additionally, FF++ includes bounding box annotations and, in some versions, manipulated region masks, thereby supporting extended tasks such as forgery localization in addition to classification. With separate training, validation, and test splits, FF++ provides a standardized and reproducible benchmark for evaluating deepfake detection models under varying levels of manipulation complexity and video quality.

Dataset 2: Celeb-DF(v2). The Celeb-DF (v2) dataset [34], short for Celebrity DeepFake Dataset, addresses the limitations found in earlier datasets by offering more realistic and visually coherent deepfake videos. It consists of approximately 590 authentic video clips featuring 59 public figures, sourced from YouTube interviews that capture a diverse range of

head poses, facial expressions, and lighting conditions. A total of 5,639 deepfake videos were produced from these real videos using advanced deepfake synthesis methods, which significantly reduce visual artifacts such as lip mismatches, flickering, and facial warping. Unlike FF++, Celeb-DF (v2) focuses solely on high-quality deepfakes without introducing artificial compression, making it more representative of real-world high-fidelity forgeries. Although it lacks mask or manipulation annotations, its high visual fidelity and absence of synthetic glitches make it a valuable dataset for testing the generalization capability and robustness of detection models trained on noisier or lower-quality datasets. Together, FF++ and Celeb-DF (v2) provide complementary testbeds, one offering variety in manipulation and compression, and the other emphasizing realism and subtlety, making them suitable for the comprehensive evaluation of deepfake detection frameworks.

4.3. Hyperparameter Configuration. The training process was carefully configured using a standard set of hyperparameters to optimize model performance while mitigating overfitting and ensuring generalizability. The key hyperparameter settings used in the proposed framework are summarized in Table 2.

Table 2. Hyperparameter configuration

Hyperparameter	Value
Optimizer	Adam
Learning Rate	0.001
Batch Size	32
Epochs	30
Learning rate Scheduler	ReduceLROnPlateau
Regularization	L2
Dropout	0.5
Validation split	5-fold

The Adam optimizer [35] was selected for its ability to adapt the learning rate during training. A learning rate scheduler was employed to adjust the rate dynamically in response to changes in validation loss. L2 regularization and dropout [36] were applied to reduce overfitting. A 5-fold cross-validation strategy was used to ensure robust performance estimation and evaluate the model's generalization across different subsets of the data.

4.4. Results and Analysis of the Preprocessing Stage. The preprocessing stage is crucial for ensuring accurate and reliable deepfake detection. Input videos are first decomposed into frames at uniform intervals

to preserve temporal coherence. BlazeFace detects faces under varying conditions, and MediaPipe Face Mesh extracts detailed facial landmarks for precise alignment. This ensures high-quality, geometrically consistent facial regions are passed to the XceptionCapsule Net, allowing the model to focus on subtle manipulations such as unnatural warping, inconsistent expressions, and temporal irregularities. Figures 5–8 illustrate successful face detection and alignment on the FF++ and Celeb-DF (v2) datasets, demonstrating the effectiveness of the preprocessing pipeline.



Fig. 5. Preprocessing result of BlazeFace and FaceMesh of fake videos for FF++ dataset



Fig. 6. Preprocessing result of BlazeFace and FaceMesh of real videos for FF++ dataset



Fig. 7. Preprocessing result of BlazeFace and FaceMesh of fake videos for Celeb-DF (v2) dataset



Fig. 8. Preprocessing result of BlazeFace and FaceMesh of real videos for Celeb-DF (v2) dataset

4.5. Performance Metrics. Performance metrics play a crucial role in assessing the effectiveness of deepfake detection models. A comprehensive set of metrics is used to quantify how well the model differentiates between authentic and manipulated content. These include classification metrics such as Accuracy, Precision, Recall, F1-Score, and Specificity. Collectively, these metrics provide detailed insights into the model's prediction quality, robustness, and reliability under real-world conditions.

The metrics used are defined as follows:

i. Accuracy. The proportion of correctly classified samples (real or fake) among all samples:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}. \quad (21)$$

ii. Precision. The proportion of samples predicted as fake that are truly fake:

$$Precision = \frac{TP}{TP + FP}. \quad (22)$$

iii. Recall. The proportion of actual fake samples that are correctly identified:

$$Recall = \frac{TP}{TP + FN}. \quad (23)$$

iv. F1-Score. The harmonic mean of precision and recall, useful for imbalanced datasets:

$$F1 - Score = \frac{2 \cdot (Precision \cdot Recall)}{Precision + Recall}. \quad (24)$$

v. Specificity. The proportion of real (negative class) samples correctly identified:

$$Specificity = \frac{TN}{TN + FP}. \quad (25)$$

vi. Area under the ROC Curve (AUC). This metric is typically used with the ROC (Receiver Operating Characteristic) curve to evaluate binary classifiers. It measures the model's ability to distinguish between the two classes (e.g., real vs. fake). Mathematically, it can be expressed as follows:

$$AUC = \int_0^1 TPR(FPR)d(FPR), \quad (26)$$

where TPR and FPR are the True Positive Rate and False Positive Rate at threshold i , and n is the number of thresholds used.

4.5.1. Cross-Validation Evaluation. To ensure robustness and generalization, a 5-fold cross-validation strategy is adopted. The dataset is partitioned into five equally sized subsets (folds). In each iteration, four folds are used for training, and the remaining fold is used for testing. This process is repeated five times, ensuring each fold serves exactly once as a test set. The final performance metrics are computed as the average of results across all folds, thereby reducing both variance and bias in model evaluation. This cross-validation approach is particularly valuable for deepfake detection, where data heterogeneity (in lighting, pose, and manipulation type) can influence model behavior. Table 3 presents the detailed results obtained from the 5-fold cross-validation on the FF++ dataset and Celeb-DF (v2) datasets, respectively. Additionally, Figure 9 illustrates the training and validation accuracy and loss curves across the five folds for the FF++ dataset, providing insights into model convergence and overfitting tendencies.

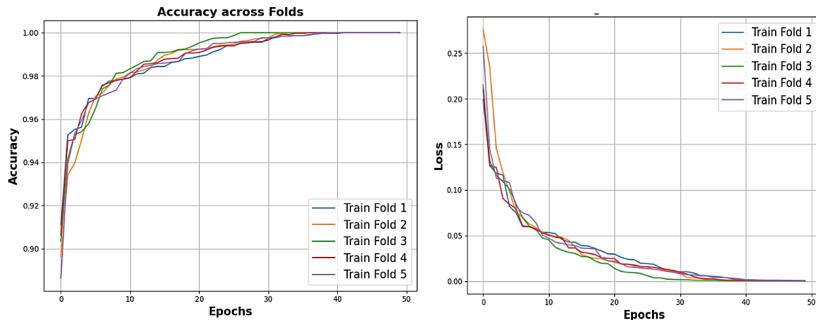


Fig. 9. Cross-validation for the accuracy and loss for FF++ dataset

Table 2. Cross-Validation Performance of the Proposed Model on FF++ and Celeb-DF (v2) Datasets

Datasets	Metrics	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Average	Mean \pm 95% CI
FF++	Accuracy	0.9667	0.9771	0.9510	0.9708	0.9708	0.9673	0.9673 ± 0.009
	Precision	0.9737	0.9718	0.9456	0.9733	0.9753	0.9679	0.9679 ± 0.011
	Recall	0.9612	0.9837	0.9591	0.9693	0.9673	0.9681	0.9681 ± 0.009
	F1-score	0.9671	0.9777	0.9523	0.9713	0.9713	0.9679	0.9679 ± 0.010
	Specificity	0.9724	0.9703	0.9427	0.9724	0.9745	0.9665	0.9665 ± 0.012
	AUC	0.9978	0.9962	0.9938	0.9957	0.9970	0.9961	0.9961 ± 0.001
Celeb-DF v2	Accuracy	0.9902	0.9872	0.9931	0.9921	0.9843	0.9894	0.9894 ± 0.003
	Precision	0.9987	0.9778	0.9906	0.9943	0.9923	0.9907	0.9907 ± 0.008
	Recall	0.9924	0.9981	0.9962	0.9905	0.9773	0.9909	0.9909 ± 0.007
	F1-score	0.9905	0.9878	0.9934	0.9924	0.9848	0.9898	0.9898 ± 0.005
	Specificity	0.9877	0.9754	0.9897	0.9938	0.9918	0.9877	0.9877 ± 0.007
	AUC	0.9998	0.9992	0.9999	0.9992	0.9989	0.9994	0.9994 ± 0.001

Table 2 presents the 5-fold cross-validation results of the proposed deepfake detection model on the FF++ and Celeb-DF (v2) datasets, including average values and 95% confidence intervals. For FF++, the model achieved an average accuracy of 96.73% with a mean AUC of 0.9961, demonstrating strong discriminative power. Precision, recall, and F1-score were consistently high across all folds, with mean values of 96.79%, 96.81%, and 96.79%, respectively. Similarly, on the Celeb-DF (v2) dataset, the model achieved a mean accuracy of 98.94% and an AUC of 0.9994, with precision, recall, and F1-score all above 98.9%, indicating highly reliable performance. The low 95% confidence intervals across all metrics highlight the model's robustness and consistent performance across different folds, confirming its generalization capability across diverse datasets and challenging deepfake scenarios. Figure 10 represents the cross-validation training and validation accuracy and loss for Celeb-DF (v2)

dataset, further corroborating the model's stable performance across different datasets and data distributions.

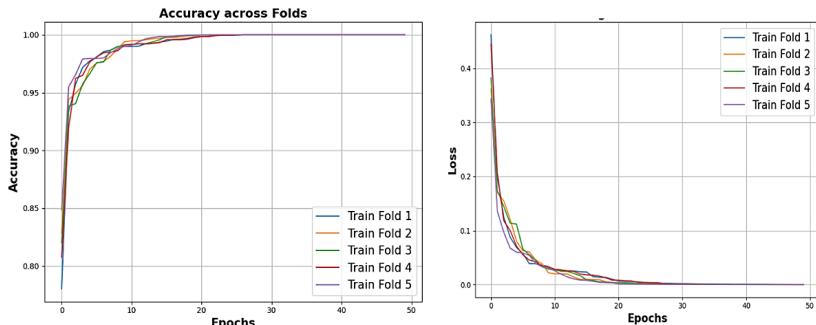


Fig. 10. Cross-validation for the accuracy and loss for Celeb-DF (v2) dataset

Figures 11 and 12 illustrate the training and validation accuracy and loss curves for the FF++ and Celeb-DF (v2) datasets, respectively, providing visual confirmation of the model's convergence and generalization effectiveness across both datasets.

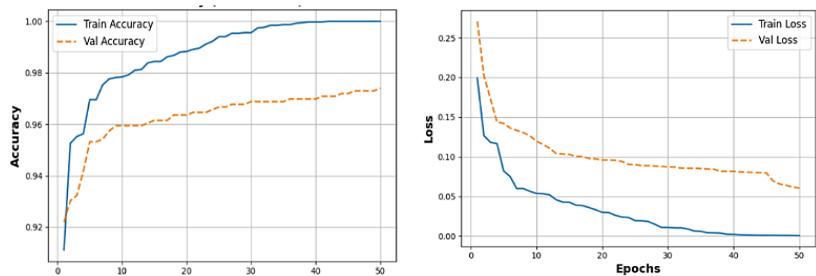


Fig. 11. Training and validation accuracy and loss of dataset 1

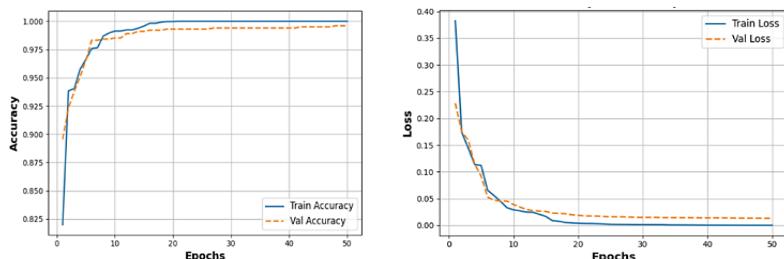


Fig. 12. Training and validation accuracy and loss of dataset 2

4.5.2. Confusion Matrix. A confusion matrix serves as a valuable tool for assessing the performance of classification models, providing an in-depth comparison between actual and predicted class labels. It categorizes outcomes into True Positives (TP), True Negatives (TN), False Positives (FP), and False Negatives (FN), facilitating accurate computation of metrics such as accuracy, precision, recall, and error rates. This visualization is especially useful for evaluating how well a model differentiates between classes, making it highly effective in binary classification scenarios such as deepfake detection.

Figure 13 presents the confusion matrices of the Dataset 1 and the Dataset 2.

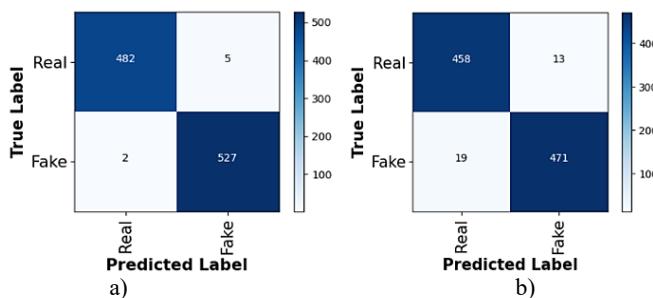


Fig. 13. Confusion Matrix: a) dataset 1, b) dataset 2

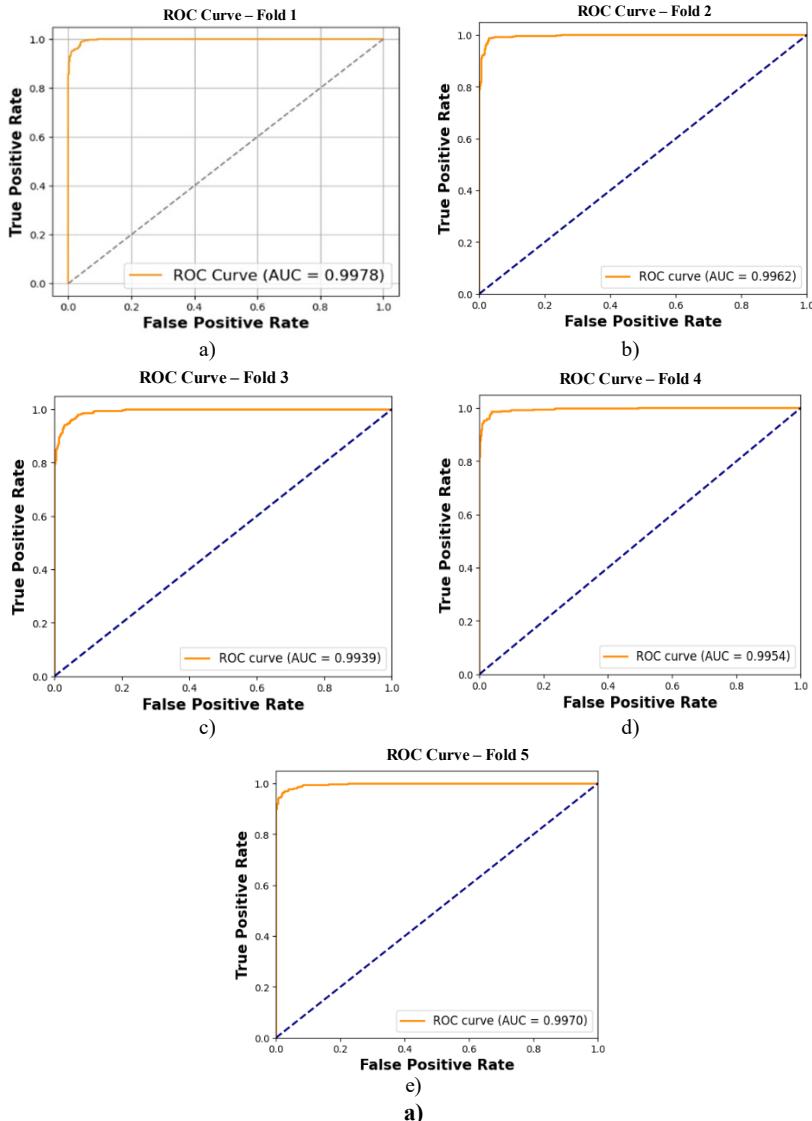
For Dataset 1(a), the model accurately classified 482 real and 527 fake instances. The model misclassified only 5 genuine instances as fake and incorrectly identified 2 manipulated samples as authentic. This distribution reflects excellent model performance with minimal misclassification, indicating high precision, recall, and overall robustness in detecting facial manipulations.

For Dataset 2(b), the model correctly identified 458 real and 471 fake videos. However, it misclassified 13 real instances as fake and 19 fake instances as real, reflecting a slightly higher error rate compared to Dataset 1. Despite this, the matrix exhibits strong diagonal dominance, affirming the model's capacity to generalize well to more challenging and realistic deepfake samples.

Overall, the confusion matrices underscore the model's high discriminative power and low error rate, particularly with Dataset 1, while still maintaining robust performance on the more visually complex Dataset 2.

4.5.3. ROC Curve. The ROC curve illustrates the relationship between the TPR, also known as sensitivity, and the FPR across varying classification thresholds. By visualizing this trade-off, the ROC curve provides insight into the model's ability to discriminate between classes regardless of the decision threshold. A key metric derived from the ROC curve is the AUC, which offers a

single scalar value to summarize performance. An AUC value closer to 1.0 indicates a high degree of separability between the positive and negative classes, signifying excellent classification capability. Figure 14 shows the ROC curves for (a) FF++ dataset and (b) Celeb-DF (v2) dataset.



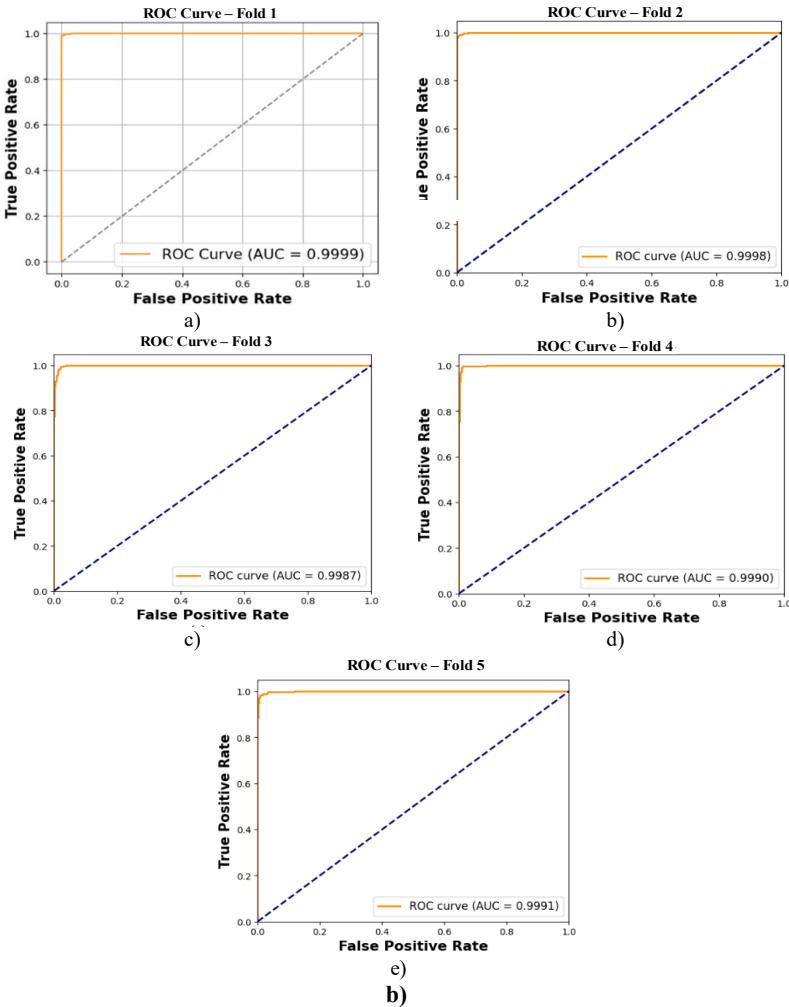


Fig. 14. ROC curve for: a) FF++ dataset, b) Celeb-DF (v2) dataset

The ROC curves, averaged across the 5-fold cross-validation, demonstrate the model's exceptional classification ability. For the FF++ dataset (a), the model achieved an average AUC of 0.9961, indicating a very high true positive rate with a minimal false positive rate across all folds. For the Celeb-DF (v2) dataset (b), the model attained an average AUC of 0.9994, reflecting near-perfect separability between real and manipulated content. These ROC curves, based on averaged cross-validation results, reaffirm the

high discriminative power and robustness of the proposed framework across different datasets, diverse conditions, and various manipulation techniques.

4.6. Comparative Analysis. This section presents a comprehensive comparative analysis of the proposed deepfake detection framework against a range of existing state-of-the-art approaches. The evaluation considers two primary performance metrics such as Accuracy and AUC measured across two benchmark datasets: FF++ and Celeb-DF (v2). The compared methods include both conventional CNN models (e.g., VGG16, InceptionV3, ResNet50, MobileNetV2, EfficientNet variants) and advanced architectures that employ hybrid learning, attention, and frequency-domain features such as MesoNet, F3-Net, RFM, GRAM, GFFD, SPSL, M2TR, GocNet, F2-Trans, BMNet, and Self-Supervised BEiT-HPR. Tables 5 and 6 summarize the comparative results on both datasets.

Table 5. The overall comparison for the FF++ dataset

Methods	FF++ dataset	
	Accuracy (%)	AUC(%)
Face cutout [23]	84	80
DWT [24]	95.13	95.49
ResNet-Swish-BiLSTM [25]	96.23	-
BMNet [26]	95.54	98.60
MLP [27]	98.00	99.94
Self-Supervised BEiT-HPR [28]	83.92	-
ConvNext-PNe [29]	97.78	99.25
CViT2 [30]	94.80	96.00
MesoNet [31]	60.51	74.55
MesoNet-Inc4 [31]	82.15	83.64
Xception [31]	89.84	98.14
EfficientNetb4 [31]	91.89	98.45
F3-Net [31]	93.78	98.55
RFM [31]	91.59	98.37
GRAM [31]	92.21	97.81
GFFD [31]	90.23	98.28
SPSL [31]	91.50	95.32
M2TR [31]	94.08	98.43
GocNet [31]	91.67	97.58
F2-Trans [31]	96.60	99.24
MSTN [31]	95.78	95.78
VGG16 [32]	78.39	78.00
InceptionV3 [32]	51.00	50.00
ResNet50 [32]	89.67	89.00
Xception [32]	73.86	73.00
MobileNetV2 [32]	76.63	76.00
EfficientNetB7 [32]	83.66	84.00
Proposed	96.67	99.78

Table 6. The overall comparison for the Celeb-DF (v2) dataset

Methods	Celeb-DF (v2) dataset	
	Accuracy (%)	AUC(%)
Face cutout [23]	92	93
DWT [24]	95.49	95.49
ResNet-Swish-BiLSTM [25]	78.33	-
BMNet [26]	80.20	75.72
MLP [27]	96.33	97.05
Self-Supervised BEiT-HPR [28]	98.25	-
ConvNext-PNe [29]	97.09	98.99
CViT2 [30]	98.30	99.00
FWA [31]	50.74	55.71
CViT [31]	51.67	60.22
Capsule [31]	63.35	62.70
MesoNet [31]	42.80	52.31
Xception [31]	55.92	67.23
BMNet [31]	80.20	75.72
VGG16 [32]	67.09	68.00
InceptionV3 [32]	55.12	52.00
ResNet50 [32]	67.09	68.00
Xception [32]	59.22	63.00
MobileNetV2 [32]	63.24	65.00
EfficientNetB7 [32]	70.08	69.00
Proposed	99.31	99.99

Footnote: The accuracy and AUC values for the proposed method correspond to the best-performing fold (Full Model) from the cross-validation experiment, used for fair comparison with state-of-the-art single-model results. Mean accuracy across all five folds (98.94%) is reported separately in Table 2, confirming consistent model performance and stable generalization.

Table 5 illustrates the comparative performance of different deepfake detection methods on the FF++ dataset. The proposed model achieves the highest performance, with an accuracy of 96.67% and an AUC of 99.78%, thereby outperforming both classical CNN-based methods and modern hybrid architectures. Traditional CNN-based models such as VGG16, InceptionV3, and MobileNetV2 show moderate performance with accuracies between 51% and 83%, indicating their limited ability to capture complex spatial-temporal inconsistencies present in manipulated videos. Recent architectures such as MesoNet, MesoNet-Inc4, and Xception deliver improved results but still fall short in generalization across diverse forgery

types. Advanced techniques such as EfficientNetB4, F3-Net, RFM, GRAM, M2TR, and F2-Trans achieve higher AUC values (above 98%), reflecting progress in feature extraction and classification precision. However, the proposed XceptionCapsule-based framework outperforms all competitors, exhibiting near-perfect discriminative capability as evidenced by its 99.78% AUC. This superior performance can be attributed to the model's ability to jointly capture spatial texture cues and temporal motion inconsistencies, while the integrated Capsule Network layer enhances dynamic feature representation and resilience to occlusions and compression artifacts.

Table 6 presents the comparative evaluation of the proposed model against state-of-the-art methods on the Celeb-DF (v2) dataset, which is known for its high-quality and challenging deepfake content. The proposed framework demonstrates remarkable superiority, achieving an accuracy of 99.31% and an AUC of 99.99%, substantially surpassing all prior methods. While traditional CNN-based detectors such as ResNet50, VGG16, and InceptionV3 achieve accuracies below 70%, specialized architectures such as BMNet, CViT, and Capsule Networks also fail to generalize effectively to complex manipulations, with most methods performing below 81% accuracy. On the other hand, transformer-based and hybrid learning approaches, such as ConvNext-PNet, CViT2, and Self-Supervised BEiT-HPR, show improved performance with accuracies exceeding 97%, yet they still fall short of the proposed model's near-perfect results. The performance of the proposed model on Celeb-DF (v2) confirms its robust generalization ability and strong resistance to unseen manipulations, even under high-fidelity synthesis and compression variations.

4.7. Ablation Study. To assess the contribution of each module within the proposed framework, an ablation experiment was conducted on the FF++ and Celeb-DF (v2) datasets. The analysis evaluates performance gains achieved by progressively integrating CapsNet, BlazeFace, MediaPipe FaceMesh, and the BiLSTM layer with the baseline Xception model.

Table 7 presents the ablation study results illustrating the contribution of each component integrated into the proposed deepfake detection framework. The baseline Xception model achieved 94.26% accuracy and 97.85% AUC, establishing the initial performance. Incorporating the CapsNet module improved feature representation and slightly increased overall accuracy to 96.03%, with an AUC of 98.91%. When combined with BlazeFace, the framework achieved improved face localization and yielded 96.30% accuracy and 99.23% AUC. The integration of MediaPipe FaceMesh further enhanced landmark precision, resulting in 96.50% accuracy and 99.64% AUC. When the BiLSTM layer was introduced, the model achieved 96.58% accuracy and 99.70% AUC,

confirming its contribution in learning temporal dependencies and motion-based cues such as blinking, head rotation, and lip synchronization. Finally, the full model, integrating all modules (Xception, CapsNet, BlazeFace, MediaPipe Face Mesh, and BiLSTM), attained the highest performance: 96.67% accuracy, 97.31% precision, 96.12% recall, 96.71% F1-score, and 99.78% AU. This demonstrates that the synergistic integration of spatial, geometric, and temporal components significantly enhances deepfake detection reliability and robustness.

Table 7. Ablation Study Showing the Impact of Different Model Components on Deepfake Detection Performance on FF++ Dataset

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)	AUC (%)
Xception only	94.26	93.40	95.10	94.24	97.85
Xception + CapsNet	96.03	95.71	95.80	96.07	98.91
XceptionCapsule + BlazeFace only	96.30	96.95	95.95	96.20	99.23
XceptionCapsule + MediaPipe FaceMesh	96.50	97.20	96.05	96.40	99.64
XceptionCapsule + BiLSTM	96.58	97.08	96.11	96.45	99.70
Full Model	96.67	97.31	96.12	96.71	99.78

On the Celeb-DF (v2) dataset (Table 2), which consists of high-fidelity and visually coherent deepfakes, the incremental impact of each module is even more pronounced. The baseline Xception model achieved 92.45% accuracy and 96.72% AUC, struggling to capture subtle manipulations. The addition of CapsNet improved the detection of fine-grained artifacts, reaching 95.84% accuracy. Incorporating BlazeFace enhanced face localization accuracy, achieving an accuracy of over 97%. MediaPipe Face Mesh further refined geometric consistency, leading to 98.72% accuracy and 99.73% AUC. Introducing the BiLSTM module significantly improved temporal understanding and motion-based detection, achieving 99.01% accuracy and 99.88% AUC by modeling frame-to-frame dependencies and identifying inconsistencies in facial dynamics. The full model achieved the best results, with 99.31% accuracy and nearly perfect AUC (99.99%), confirming that combining hierarchical spatial modeling, geometric precision, and temporal learning substantially improves deepfake detection performance and generalization in complex real-world scenarios.

Table 8. Ablation Study Showing the Impact of Different Model Components on Deepfake Detection Performance on Celeb-DF (v2) Dataset

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)	AUC (%)
Xception only	92.45	91.62	93.01	92.30	96.72
Xception + CapsNet	95.84	95.41	95.97	95.69	98.44
XceptionCapsule + BlazeFace only	97.25	97.10	97.42	97.26	99.11
XceptionCapsule + MediaPipe FaceMesh	98.72	98.45	98.80	98.62	99.73
XceptionCapsule + BiLSTM	99.01	98.80	99.25	99.02	99.88
Full Model	99.31	99.06	99.62	99.34	99.99

4.8. Discussion. The proposed Face and Motion-Aware Detection Framework effectively integrates spatial and temporal features to detect subtle facial artifacts and motion inconsistencies in deepfakes. BlazeFace provides robust face localization under varying conditions, and MediaPipe Face Mesh ensures precise landmark extraction. The XceptionCapsule Net preserves hierarchical spatial relationships, enabling the detection of fine-grained forgery cues. Additionally, the integration of a BiLSTM layer enables the framework to model temporal dependencies by learning motion dynamics such as blinking, lip movement, and head rotation across consecutive frames, enhancing temporal consistency in detection. The experimental results on the FF++ and Celeb-DF (v2) datasets demonstrate strong generalization, outperforming several state-of-the-art methods. Ablation studies confirm the contribution of each module, highlighting the robustness and adaptability of the framework to different manipulation techniques and challenging conditions such as low resolution, compression, and subtle manipulations. These characteristics position the framework as a promising solution for real-world media forensics and content authentication.

5. Conclusion. This study introduces a robust Face and Motion-Aware Detection Framework that advances deepfake detection by combining spatial and temporal analysis. Benchmark evaluations demonstrate its superior performance and generalization compared to existing methods. The framework's design allows adaptability to various types of manipulations and real-world conditions. For future work, the framework can be extended to multi-modal analysis by incorporating audio and textual cues, which would improve the detection of lip-sync or dialogue-incoherent deepfakes. Further enhancements could include transformer-based architectures to strengthen temporal modeling. Finally,

testing on in-the-wild deepfake samples and evaluating the feasibility of real-time deployment on social media or video streaming platforms are crucial steps for ensuring the practical applicability of the system against increasingly sophisticated generative manipulations.

References

1. O'Toole A.J., Castillo C.D. Face recognition by humans and machines: three fundamental advances from deep learning. *Annual Review of Vision Science*. 2021. vol. 7(1). pp. 543–570.
2. Fola-Rose A., Solomon E., Bryant K., Woubie A. A Systematic Review of Facial Recognition Methods: Advancements, Applications, and Ethical Dilemmas. *IEEE International Conference on Information Reuse and Integration for Data Science (IRI)*. 2024. pp. 314–319.
3. EL Fadel N. Facial Recognition Algorithms: A Systematic Literature Review. *Journal of Imaging*. 2025. vol. 11(2).
4. Wu Y. Facial Recognition Technology: College Students' Perspectives in the US. *Trends in Sociology*. 2024. vol. 2(2). pp. 56–69. DOI: 10.61187/ts.v2i2.119.
5. Dang M., Nguyen T.N. Digital face manipulation creation and detection: A systematic review. *Electronics*. 2023. vol. 12(16).
6. Masood M., Nawaz M., Malik K.M., Javed A., Irtaza A., Malik H. Deepfakes generation and detection: State-of-the-art, open challenges, countermeasures, and way forward. *Applied intelligence*. 2023. vol. 53(4). pp. 3974–4026.
7. Akkem Y., Biswas S.K., Varanasi A. A comprehensive review of synthetic data generation in smart farming by using variational autoencoder and generative adversarial network. *Engineering Applications of Artificial Intelligence*. 2024. vol. 131.
8. Alqahtani H., Kavakli-Thorne M., Kumar G. Applications of generative adversarial networks (gans): An updated review. *Archives of Computational Methods in Engineering*. 2021. vol. 28. pp. 525–552.
9. Sun X., Chen S., Yao T., Liu H., Ding S., Ji R. Diffusionfake: Enhancing generalization in deepfake detection via guided stable diffusion. *Advances in Neural Information Processing Systems*. 2024. vol. 37. pp. 101474–101497.
10. Ge Y., Xu J., Zhao B.N., Joshi N., Itti L., Vineet V. Dall-e for detection: Language-driven compositional image synthesis for object detection. *arXiv preprint arXiv:2206.09592*. 2022.
11. Zhao H., Liang T., Davari S., Kim D. Synthesizing Reality: Leveraging the Generative AI-Powered Platform Midjourney for Construction Worker Detection. *arXiv preprint arXiv:2507.13221*. 2025.
12. Zhou K.Z., Choudhry A., Gumusel E., Sanfilippo M.R. Sora is Incredible and Scary": Emerging Governance Challenges of Text-to-Video Generative AI Models. *arXiv preprint arXiv:2406.11859*. 2024.
13. Qadir A., Mahum R., El-Meligy M.A., Ragab A.E., AlSalman A., Awais M. An efficient deepfake video detection using robust deep learning. *Heliyon*, 2024. vol. 10(5).
14. Bhattacharyya C., Wang H., Zhang F., Kim S., Zhu X. Diffusion deepfake. *arXiv preprint arXiv:2404.01579*. 2024.
15. Al-Khazraji S.H., Saleh H.H., Khalid A.I., Mishkhal I.A. Impact of deepfake technology on social media: Detection, misinformation and societal implications. *The Eurasia Proceedings of Science Technology Engineering and Mathematics*. 2023. vol. 23. pp. 429–441.

-
16. Jbara W.A., Hussein N.A.H.K., Soud J.H. Deepfake Detection in Video and Audio Clips: A Comprehensive Survey and Analysis. *Mesopotamian Journal of CyberSecurity*. 2024. vol. 4(3). pp. 233–250.
 17. Arya M., Goyal U., Chawla S. A Study on Deep Fake Face Detection Techniques. 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC). IEEE, 2024. pp. 459–466.
 18. Rajeev A., Raviraj P. An insightful analysis of digital forensics effects on networks and multimedia applications. *SN Computer Science*. 2023. vol. 4(2).
 19. Sheremet O.I., Sadovoi O.V., Harshanov D.V., Kovalchuk S., Sheremet K.S., Sokhina Y.V. Efficient face detection and replacement in the creation of simple fake videos. *Applied Aspects of Information Technology*. 2023. vol. 6(3). pp. 286–303.
 20. Wang J., Yuan S., Lu T., Zhao H., Zhao Y. Video-based real-time monitoring of engagement in E-learning using MediaPipe through multi-feature analysis. *Expert Systems with Applications*. 2025. vol. 288. DOI: 10.1016/j.eswa.2025.128239.
 21. Chollet F. Xception: Deep learning with depthwise separable convolutions, in: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017. pp. 1251–1258.
 22. Joshi D., Kashyap A., Arora P. CapsNet-Based Deep Learning Approach for Robust Image Forgery Detection. 10th International Conference on Signal Processing and Communication (ICSC). IEEE, 2025. pp. 308–314.
 23. Alanazi F., Ushaw G., Morgan G. Improving detection of deepfakes through facial region analysis in images. *Electronics*. 2024. vol. 13(1). DOI: 10.3390/electronics13010126.
 24. Hasanaath A.A., Luqman H., Katib R., Anwar S. FSBI: Deepfake detection with frequency enhanced self-blended images. *Image and Vision Computing*. 2025. vol. 154.
 25. Qadir A., Mahum R., El-Meligy M.A., Ragab A.E., AlSalman A., Awais M. An efficient deepfake video detection using robust deep learning. *Heliyon*, 2024. vol. 10(5).
 26. Xiong D., Wen Z., Zhang C., Ren D., Li W. BMNet: Enhancing Deepfake Detection through BiLSTM and Multi-Head Self-Attention Mechanism. *IEEE Access*. 2025. vol. 13. pp. 21547–21556. DOI: 10.1109/ACCESS.2025.3533653.
 27. Naskar G., Mohiuddin S., Malakar S., Cuevas E., Sarkar R. Deepfake detection using deep feature stacking and meta-learning. *Heliyon*. 2024. vol. 10(4).
 28. Al Redhaei A., Fraihat S., Al-Betar M.A. A self-supervised BEiT model with a novel hierarchical patchReducer for efficient facial deepfake detection. *Artificial Intelligence Review*. 2025. vol. 58(9).
 29. Ilyas H., Javed A., Malik K.M. ConvNext-PNet: An interpretable and explainable deep-learning model for deepfakes detection. *IEEE International Joint Conference on Biometrics (IJCB)*. 2024. pp. 1–9.
 30. Deressa D.W., Lambert P., Van Wallendael G., Atnafu S., Mareen H. Improved Deepfake Video Detection Using Convolutional Vision Transformer. *IEEE Gaming, Entertainment, and Media Conference (GEM)*. 2024. pp. 1–6.
 31. Gong R., He R., Zhang, D., Sangaiah A.K., Alenazi M.J. Robust face forgery detection integrating local texture and global texture information. *EURASIP Journal on Information Security*. 2025(1). vol. 3.
 32. Saikia P., Dholaria D., Yadav P., Patel V., Roy M. A hybrid CNN-LSTM model for video deepfake detection by leveraging optical flow features. International joint conference on neural networks (IJCNN). IEEE, 2022. pp. 1–7.
 33. Rossler A., Cozzolino D., Verdoliva L., Riess C., Thies J., et al., Faceforensics: A Large-Scale Video Dataset for Forgery Detection in Human Faces. *arXiv preprint arXiv:1803.09179*. 2018.

34. Li Y., Yang X., Sun P., Qi H., Lyu S. Celeb-df: A largescale challenging dataset for deepfake forensics. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020. pp. 3207–3216.
35. Akbar A.F., Ayu P.D.W., Hostiadi D.P. Performance Analysis of Deep Learning Architectures in Classifying Fake and Real Images. JUITA: Jurnal Informatika. 2025. pp. 167–176.
36. Khan S.B., Gupta M., Gopinathan B., Thyluru RamaKrishna M., Saraee M., Mashat A., Almusharraf A. DeepFake Detection: Evaluating the Performance of EfficientNetV2-B2 on Real vs. Fake Image Classification. IET Image Processing. 2025. vol. 19(1).

Rajeev Aishwarya — Student, GSSS Institute of Engineering and Technology for Women. Research interests: deepfake detection, XceptionCapsule Net, Face Mesh, BlazeFace, facial landmark extraction, video forensics. The number of publications — 1. aishwaryarajeev654@gmail.com; KRS Road, Metagalli, 570016, Karnataka, Mysore, India; office phone: +91(0821)258-1305.

P. Raviraj — Professor, GSSS Institute of Engineering and Technology for Women. Research interests: deepfake detection, XceptionCapsule Net, Face Mesh, BlazeFace, facial landmark extraction, video forensics, image processing. The number of publications — 75. ravirajp654@gmail.com; KRS Road, Metagalli, 570016, Karnataka, Mysore, India; office phone: +91(0821)258-1305.

А. РАДЖИВ, РАВИРАДЖ П.

**МОДЕЛЬ ДЛЯ ОБНАРУЖЕНИЯ ДИПФЕЙКОВ С УЧЕТОМ
ПРОСТРАНСТВЕННО-ВРЕМЕННЫХ И ПОВЕДЕНЧЕСКИХ
ПРИЗНАКОВ НА ОСНОВЕ ОБЪЕДИНЕНИЯ
XCEPTIONCAPSULE**

Раджив А., Равирадж П. Модель для обнаружения дипфейков с учетом пространственно-временных и поведенческих признаков на основе объединения XceptionCapsule.

Аннотация. Обнаружение дипфейков по-прежнему представляет собой серьезную проблему, главным образом из-за ключевых ограничений существующих методов, включая зависимость от анализа отдельных кадров, уязвимость к видео низкого разрешения или сжатым видео, а также неспособность улавливать временные несоответствия. Кроме того, традиционные методы обнаружения лиц часто дают сбой в сложных условиях, таких как плохое освещение или окклюзия, а многие модели не справляются с тонкими манипуляциями из-за неадекватного извлечения признаков и переобучения на ограниченных наборах данных. Для устранения недостатков существующих подходов к обнаружению дипфейков в данном исследовании предлагается система обнаружения лиц и движений, которая объединяет как пространственную, так и временную информацию. Работа системы начинается с этапа предварительной обработки, на котором видеокадры извлекаются с фиксированной частотой для обеспечения временной согласованности. Области лица и детальные ориентиры точно определяются с помощью BlazeFace и MediaPipe Face Mesh. Затем эти признаки обрабатываются с помощью предлагаемой сети XceptionCapsule Net, которая сочетает в себе возможности извлечения пространственных признаков модели Xception с иерархическим и учитывающим ракурс представлением капсулных сетей (CapsNet), а также возможность моделирования временных зависимостей двунаправленного слоя долгой краткосрочной памяти (BiLSTM). Архитектура включает в себя глобальный усредняющий пулинг, сглаживание и полно связанные слои с сигмоидной функцией активации для бинарной классификации. Обширные оценки на наборах данных FaceForensics++ (FF++) и Celeb-DF демонстрируют высокую производительность, достигая точности до 99,31% и площади под кривой (AUC) 99,99%. Результаты подтверждают эффективность, точность и обобщающую способность системы для видео различного качества и сценариев манипуляций.

Ключевые слова: обнаружение дипфейков, XceptionCapsule Net, Face Mesh, BlazeFace, извлечение лицевых ориентиров, видеокриминалистика.

Литература

1. O'Toole A.J., Castillo C.D. Face recognition by humans and machines: three fundamental advances from deep learning. *Annual Review of Vision Science*. 2021. vol. 7(1). pp. 543–570.
2. Fola-Rose A., Solomon E., Bryant K., Woubie A. A Systematic Review of Facial Recognition Methods: Advancements, Applications, and Ethical Dilemmas. *IEEE International Conference on Information Reuse and Integration for Data Science (IRI)*. 2024. pp. 314–319.
3. EL Fadel N. Facial Recognition Algorithms: A Systematic Literature Review. *Journal of Imaging*. 2025. vol. 11(2).

4. Wu Y. Facial Recognition Technology: College Students' Perspectives in the US. Trends in Sociology. 2024. vol. 2(2). pp. 56–69. DOI: 10.61187/ts.v2i2.119.
5. Dang M., NguyenT.N. Digital face manipulation creation and detection: A systematic review. Electronics. 2023. vol. 12(16).
6. Masood M., Nawaz M., Malik K.M., Javed A., Irtaza A., Malik H. Deepfakes generation and detection: State-of-the-art, open challenges, countermeasures, and way forward. Applied intelligence. 2023. vol. 53(4). pp. 3974–4026.
7. Akkem Y., Biswas S.K., Varanasi A. A comprehensive review of synthetic data generation in smart farming by using variational autoencoder and generative adversarial network. Engineering Applications of Artificial Intelligence. 2024. vol. 131.
8. Alqahtani H., Kavakli-Thorne M., Kumar G. Applications of generative adversarial networks (gans): An updated review. Archives of Computational Methods in Engineering. 2021. vol. 28. pp. 525–552.
9. Sun X., Chen S., Yao T., Liu H., Ding S., Ji R. Diffusionfake: Enhancing generalization in deepfake detection via guided stable diffusion. Advances in Neural Information Processing Systems. 2024. vol. 37. pp. 101474–101497.
10. Ge Y., Xu J., Zhao B.N., Joshi N., Itti L., Vineet V. Dall-e for detection: Language-driven compositional image synthesis for object detection. arXiv preprint arXiv:2206.09592. 2022.
11. Zhao H., Liang T., Davari S., Kim D. Synthesizing Reality: Leveraging the Generative AI-Powered Platform Midjourney for Construction Worker Detection. arXiv preprint arXiv:2507.13221. 2025.
12. Zhou K.Z., Choudhry A., Gumusel E., Sanfilippo M.R. Sora is Incredible and Scary": Emerging Governance Challenges of Text-to-Video Generative AI Models. arXiv preprint arXiv:2406.11859. 2024.
13. Qadir A., Mahum R., El-Meligy M.A., Ragab A.E., AlSalman A., Awais M. An efficient deepfake video detection using robust deep learning. Heliyon, 2024. vol. 10(5).
14. Bhattacharyya C., Wang H., Zhang F., Kim S., Zhu X. Diffusion deepfake. arXiv preprint arXiv:2404.01579. 2024.
15. Al-Khazraji S.H., Saleh H.H., Khalid A.I., Mishkhal I.A. Impact of deepfake technology on social media: Detection, misinformation and societal implications. The Eurasia Proceedings of Science Technology Engineering and Mathematics. 2023. vol. 23. pp. 429–441.
16. Jbara W.A., Hussein N.A.H.K., Soud J.H. Deepfake Detection in Video and Audio Clips: A Comprehensive Survey and Analysis. Mesopotamian Journal of CyberSecurity. 2024. vol. 4(3). pp. 233–250.
17. Arya M., Goyal U., Chawla S. A Study on Deep Fake Face Detection Techniques. 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC). IEEE, 2024. pp. 459–466.
18. Rajeev A., Raviraj P. An insightful analysis of digital forensics effects on networks and multimedia applications. SN Computer Science. 2023. vol. 4(2).
19. Sheremet O.I., Sadovoi O.V., Harshavon D.V., Kovalchuk S., Sheremet K.S., Sokhina Y.V. Efficient face detection and replacement in the creation of simple fake videos. Applied Aspects of Information Technology. 2023. vol. 6(3). pp. 286–303.
20. Wang J., Yuan S., Lu T., Zhao H., Zhao Y. Video-based real-time monitoring of engagement in E-learning using MediaPipe through multi-feature analysis. Expert Systems with Applications. 2025. vol. 288. DOI: 10.1016/j.eswa.2025.128239.
21. Chollet F. Xception: Deep learning with depthwise separable convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition. 2017. pp. 1251–1258.

22. Joshi D., Kashyap A., Arora P. CapsNet-Based Deep Learning Approach for Robust Image Forgery Detection. 10th International Conference on Signal Processing and Communication (ICSC). IEEE, 2025. pp. 308–314.
23. Alanazi F., Ushaw G., Morgan G. Improving detection of deepfakes through facial region analysis in images. *Electronics*. 2024. vol. 13(1). DOI: 10.3390/electronics13010126.
24. Hasanaath A.A., Luqman H., Katib R., Anwar S. FSBI: Deepfake detection with frequency enhanced self-blended images. *Image and Vision Computing*. 2025. vol. 154.
25. Qadir A., Mahum R., El-Meligy M.A., Ragab A.E., AlSalman A., Awais M. An efficient deepfake video detection using robust deep learning. *Heliyon*, 2024. vol. 10(5).
26. Xiong D., Wen Z., Zhang C., Ren D., Li W. BMNet: Enhancing Deepfake Detection through BiLSTM and Multi-Head Self-Attention Mechanism. *IEEE Access*. 2025. vol. 13. pp. 21547–21556. DOI: 10.1109/ACCESS.2025.3533653.
27. Naskar G., Mohiuddin S., Malakar S., Cuevas E., Sarkar R. Deepfake detection using deep feature stacking and meta-learning. *Heliyon*. 2024. vol. 10(4).
28. Al Redhaei A., Fraihat S., Al-Betar M.A. A self-supervised BEiT model with a novel hierarchical patchReducer for efficient facial deepfake detection. *Artificial Intelligence Review*. 2025. vol. 58(9).
29. Ilyas H., Javed A., Malik K.M. ConvNext-PNet: An interpretable and explainable deep-learning model for deepfakes detection. *IEEE International Joint Conference on Biometrics (IJCB)*. 2024. pp. 1–9.
30. Deressa D.W., Lambert P., Van Wallendael G., Atnafu S., Mareen H. Improved Deepfake Video Detection Using Convolutional Vision Transformer. *IEEE Gaming, Entertainment, and Media Conference (GEM)*. 2024. pp. 1–6.
31. Gong R., He R., Zhang, D., Sangaiyah A.K., Alenazi M.J. Robust face forgery detection integrating local texture and global texture information. *EURASIP Journal on Information Security*. 2025(1). vol. 3.
32. Saikia P., Dholaria D., Yadav P., Patel V., Roy M. A hybrid CNN-LSTM model for video deepfake detection by leveraging optical flow features. *International joint conference on neural networks (IJCNN)*. IEEE, 2022. pp. 1–7.
33. Rossler A., Cozzolino D., Verdoliva L., Riess C., Thies J., et al., Faceforensics: A Large-Scale Video Dataset for Forgery Detection in Human Faces. *arXiv preprint arXiv:1803.09179*. 2018.
34. Li Y., Yang X., Sun P., Qi H., Lyu S. Celeb-df: A largescale challenging dataset for deepfake forensics. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020. pp. 3207–3216.
35. Akbar A.F., Ayu P.D.W., Hostiadi D.P. Performance Analysis of Deep Learning Architectures in Classifying Fake and Real Images. *JUITA: Jurnal Informatika*. 2025. pp. 167–176.
36. Khan S.B., Gupta M., Gopinathan B., Thyluru RamaKrishna M., Saraee M., Mashat A., Almusharraf A. DeepFake Detection: Evaluating the Performance of EfficientNetV2-B2 on Real vs. Fake Image Classification. *IET Image Processing*. 2025. vol. 19(1).

Раджив Аишвария — студент, Инженерный институт для женщин в Майсуре. Область научных интересов: обнаружение дипфейков, XceptionCapsule Net, Face Mesh, BlazeFace, извлечение лицевых ориентиров, видеокриминалистика. Число научных публикаций — 1. aishwaryarajeev654@gmail.com; KRS Road, Метагалли, 570016, Карнатака, Майсур, Индия; р.т.: +91(0821)258-1305.

П. Равирадж — профессор, Инженерный институт для женщин в Майсуре. Область научных интересов: обнаружение дипфейков, XceptionCapsule Net, Face Mesh, BlazeFace, извлечение лицевых ориентиров, видеокриминалистика, обработка изображений. Число научных публикаций — 75. ravirajp654@gmail.com; KRŚ Роад, Метагалли, 570016, Карнатака, Майсур, Индия; р.т.: +91(0821)258-1305.

IU. LEZHENIN, N. BOGACH

AN INPUT-SYNCHRONOUS BLOCKWISE DECODING ALGORITHM FOR CTC-AED SPEECH RECOGNITION

Lezhenin I., Bogach N. An Input-synchronous Blockwise Decoding Algorithm for CTC-AED Speech Recognition.

Abstract. Automatic speech recognition (ASR) systems for real-life scenarios are required to process audio streams of arbitrary length with stable accuracy under limited computational resources. While the joint connectionist temporal classification (CTC) and attention-based encoder-decoder (AED) model delivers high recognition quality, its vanilla form is unable to meet these requirements. This paper proposes an input-synchronous blockwise decoding algorithm for the joint CTC-AED model. The algorithm processes overlapping blocks of audio synchronously with the input frames, utilizing CTC alignment to determine the proper context from the overlapping part for the AED component. The fixed block length ensures predictable and limited resource consumption and avoids long-form speech generalization issues, while the overlap mitigates WER degradation caused by edge effects. Unlike existing methods, the proposed approach requires neither model architecture modifications nor a special training procedure, while also supporting block overlapping. The word error rate (WER) performance of the algorithm is studied with respect to block size and overlap size.

Keywords: streaming automatic speech recognition (ASR), blockwise decoding, end-to-end, CTC, AED.

1. Introduction. Today, end-to-end (E2E) approaches for automatic speech recognition (ASR) have a prominent position in industrial system development and attract significant research interest. In contrast to a classical ASR system based on HMM-DNN framework [1], where acoustic and language modelling is carried out independently, an E2E system models speech integrally, which provides higher recognition quality.

There are three broad classes of E2E systems: connectionist temporal classification (CTC) [2], recurrent neural network transducer (RNN-T) [3] and attention encoder-decoder (AED) [4]. The CTC model assumes conditional independence between output tokens (language units: phones, graphemes, words). Conversely, RNN-T and AED models treat output tokens as mutually dependent, thereby achieving a higher degree of speech modelling integration. AED provides the better recognition quality than CTC or RNN-T [5] and can be extended to multilanguage [6] or multitask scenarios, e.g., speaker-attributed ASR [7]. However, the highest performance is obtained by combining CTC and AED models [8]. The joint CTC-AED model is the de facto standard for ASR systems with SOTA recognition quality.

A crucial part of any ASR system is the decoding algorithm. There are two approaches for CTC-AED model decoding [9]. The CTC model is decoded synchronously with the input sequence of feature frames. This

algorithm can be extended to CTC-AED by using AED as an additional scorer, similar to an external language model. This type of decoding is often referred to as input-synchronous (i-sync) decoding. The AED model is decoded in an autoregressive manner, i.e., synchronously with the output sequence of language tokens. Similarly, the algorithm extension for CTC-AED uses a CTC model as an additional scorer. It is also referred to as output-synchronous (o-sync) decoding.

The AED model and the succeeding CTC-AED model were initially designed for a non-streaming scenario, where the whole input audio is processed in a single run. These models have the following limitations:

1. To process audio of arbitrary length, unbounded computational resources are required. The computation time and the amount of consumed memory depend on the audio length. The quadratic time and memory complexity [10] of the transformer-based AED implementations make the problem even worse.
2. The result of recognition will be obtained only when processing is finished. There is no defined way to extract an intermediate recognition result tied to a specific time position with controlled latency.
3. AED-based models are sensitive to the lengths of input and output sequences, and may not generalize well to long-form speech recognition [11]. Especially, transformer-based AED tends to overfit to particular input length [12]. The model shows performance degradation when length of input audio does not correspond to the length distribution seen during training.

These effects are not acceptable for most of real-life commercial ASR applications, where computational resources are limited, intermediate results are required, and recognition quality should be stable. These requirements are highly related to the concept of streaming ASR system. Thus, CTC-AED model and corresponding decoding algorithm require streaming modifications to make them more suitable for commercial scenario.

Two approaches to developing streaming CTC-AED systems can be distinguished. These approaches differ in model design perspective.

The first approach involves developing a strategy to limit the input context of the attention module that is between encoder and decoder. Monotonic chunkwise attention (MoChA) [13] is one of the first conventional modifications for the RNN-based AED model. MoChA model scans encoder output to predict a frame where the next output should be generated by the decoder, and then uses a local window to the left of the selected frame to compute attention. MoChA

was also adapted for transformer-based AED [14] as a form of cross-attention. Similar methods were proposed and studied, e.g., stable monotonic chunkwise attention (sMoChA) [15], monotonic truncated attention (MTA) [15, 16], and monotonic multihead attention (MMA) [17]. These methods were initially proposed for AED model, but can be easily extended to joint CTC-AED model for both i-sync and o-sync decoding algorithms. The triggered attention (TA) [18] was developed for CTC-AED model directly and also falls under considered approach. It selects the frames required for next token prediction using CTC output. Since TA needs time alignment of CTC scores, it is a natural extension to i-sync decoding algorithm.

Methods in the first approach allow building streaming versions of CTC-AED with low latency, but they cause significant modification of training and decoding procedures, and also may cause performance degradation due to enforcing monotony and locality of attention.

The second approach is to process input audio in a blockwise manner. The input audio is split into sequential blocks, and then each block is processed by an ASR model. The non-overlapping blockwise o-sync decoding algorithms which do not require any model and training procedure modification were proposed in [19, 20]. It is shown that in o-sync setup the detection of block end requires additional processing, e.g., analysis of token repetitions [19] or counting the expected number of tokens in block using CTC [20]. Other attempts include model training with a special token, that denotes the end of the block [21]. The model is trained on overlapping blocks, which overlap that allows mitigating edge effects, e.g., when a word is split between adjacent blocks.

Methods in the second approach typically cannot provide low latency, which equals the block length. But with a sufficiently large block size, the blockwise decoding provides word error rate (WER) performance close to the non-streaming scenario, since there are no attention monotonicity restrictions within a block. Also, each block is processed uniformly, so these methods are easier to implement and can be efficiently optimized for batch processing.

This paper proposes an i-sync blockwise decoding algorithm for the CTC-AED ASR system. Its main idea is to process overlapping blocks input-synchronously, using CTC alignment to determine the proper context from the overlapping part for the AED model. It allows processing blocks with arbitrary overlap while maintaining correspondence between inference and training for the AED part. Thus, the algorithm avoids the end-of-block detection problem, requires neither model architecture modifications nor special training procedure, and supports overlapping.

The paper is structured as follows. Section 2 describes the proposed blockwise decoding algorithm, and Section 3 presents a study on the WER performance of the decoding algorithm with respect to block size and overlap size.

2. Blockwise i-sync CTC-AED decoding algorithm. This section describes the proposed algorithm. The first part describes the CTC-AED model scoring for the basic non-streaming scenario. The second part proposes scoring procedure modifications for a blockwise streaming scenario. The third part formulates the decoding scheme and the corresponding algorithm. The last part provides an optimization for the proposed scheme.

2.1. Scoring in a non-streaming scenario. In a non-streaming scenario, the CTC-AED model processes a sequence of input features $\mathbf{x}_{1:T} \in \mathbb{R}^{T \times d_x}$. Here, d_x is the dimension of features, and T is the length of input sequences. The encoder, which is part of the CTC-AED model, encodes the input features into a sequence of acoustic embeddings:

$$\mathbf{h}_{1:T'} = \mathcal{E}(\mathbf{x}_{1:T}), \quad \mathbf{h}_{1:T'} \in \mathbb{R}^{T' \times d_h},$$

where d_h is the embedding dimension and T' is the length of embedding sequence. Typically, the encoder is an RNN or Transformer neural network, that is prepended with convolution layers. The convolution layers perform downsampling and, thus, $T' = \lceil T/k \rceil$, where k is a downsampling factor. To simplify the notation, let $k = 1$ and $T' = T$.

The acoustic embeddings $\mathbf{h}_{1:T}$ are used by both CTC and AED parts separately to estimate the probability of a given output token sequence $u_{1:l} \in \mathcal{U}^l$, where \mathcal{U} is a token alphabet, e.g., words, phonemes, or BPE tokens, and l is the length of token sequence.

The AED part predicts the probability of the next token u_l conditioned on its history $u_{1:l-1}$ and the entire input sequence of embeddings $\mathbf{h}_{1:T}$:

$$P_{AED}(u_{1:l} | \mathbf{h}_{1:T}) = \prod_{l'=1}^l P_{AED}(u_{l'} | u_{1:l'-1}, \mathbf{h}_{1:T}). \quad (1)$$

The probability $P_{AED}(u_{l'} | u_{1:l'-1}, \mathbf{h}_{1:T})$ is produced by the decoder that is typically implemented as an RNN or Transformer neural network with softmax activation in the last layer.

The CTC part estimates the probability token u_l that will be emitted on a given acoustic embedding \mathbf{h}_t without any conditional dependence on other tokens:

$$\begin{aligned}
P_{CTC}(u_{1:l}|\mathbf{h}_{1:t}) &= \sum_{a_{1:t} \in \mathcal{B}^{-1}(u_{1:l})} P_{CTC}(a_{1:t}|\mathbf{h}_{1:t}) \\
&= \sum_{a_{1:t} \in \mathcal{B}^{-1}(u_{1:l'})} \prod_{t'=1}^t P_{CTC}(a_{t'}|\mathbf{h}_{t'}).
\end{aligned} \tag{2}$$

In the equation above $a_{1:t} \in \mathcal{U}_\epsilon^t$, where $\mathcal{U}_\epsilon = \mathcal{U} \cup \{\epsilon\}$, is a CTC alignment between the output and input sequences. Let $\mathcal{B} : \mathcal{U}_\epsilon^t \rightarrow \mathcal{U}^l$ be the CTC mapping that converts an alignment $a_{1:t}$ to a token sequence $u_{1:l}$. The conversion consists of two steps: 1) remove consecutive duplicates, 2) remove ϵ symbols. The $\mathcal{B}^{-1}(u_{1:l})$ denotes the set of all alignments that correspond to $u_{1:l}$. The probability $P_{CTC}(a_t|\mathbf{h}_t)$ is typically predicted by a simple neural network that consists of a linear layer with softmax activation.

For i-sync decoding, the total probability of a given token sequence $u_{1:l}$ is estimated on each time step t as:

$$P_t(u_{1:l}) = P_{CTC}(u_{1:l}|\mathbf{h}_{1:t}) \cdot P_{AED}(u_{1:l}, \mathbf{h}_{1:T})^\alpha,$$

where α is an empirically chosen scale factor for the AED part. The goal of decoding is to find the best sequence $u_{1:l}$ that yields the highest probability $P_T(u_{1:l})$.

2.2. Scoring in a blockwise streaming scenario. In a blockwise streaming scenario, let the input be a sequence of B overlapping blocks of the length T_b : $\{\mathbf{x}_{b,1:T_b}\}_{b=1}^B$, where $\mathbf{x}_{b,1:T_b} \in \mathbb{R}^{T_b \times d_x}$ is the b -th block. In each block, the first T_c and last T_c frames overlap with adjacent blocks, considered as context. The central $T_b - 2T_c$ frames are used for processing. Thus, there is a correspondence: $\mathbf{x}_{b-1, T_b-2T_c+t} = \mathbf{x}_{b,t}$ for $t \in [1, 2T_c]$. To provide context and the full length for the last block, the input sequence is padded with zeros on both sides. Figure 1 illustrates padding and splitting procedures.

The encoder processes each input feature block independently producing blocks of embeddings:

$$\mathbf{h}_{b,1:T_b} = \mathcal{E}(\mathbf{x}_{1:T_b}), \quad \mathbf{h}_{b,1:T_b} \in \mathbb{R}^{T_b \times d_h}.$$

However, the encoder may have mutable internal state, which allowing it to retain long-term acoustic information.

The CTC model predicts the probability for single embedding at a time. It can be easily extended to blockwise processing by substituting a concatenation into 2. This yields:

$$\mathbf{h}_{1:T} = [\mathbf{h}_{1,T_c:T_b-T_c}, \mathbf{h}_{2,T_c:T_b-T_c}, \dots, \mathbf{h}_{B,T_c:T_b-T_c}],$$

$$P_{CTC}(u_{1:l} | \{\mathbf{h}_{b',1:T_b}\}_{b'=1}^{b-1}, \mathbf{h}_{b,1:t}) \\ = \sum_{a_{1:t} \in \mathcal{B}^{-1}(u_{1:l'})} \prod_{b'=1}^{b-1} \prod_{t'=1+T_c}^{T_b-T_c} P_{CTC}(a_{t'} | \mathbf{h}_{b',t'}) \prod_{t'=1+T_c}^t P_{CTC}(a_{t'} | \mathbf{h}_{b,t'}). \quad (3)$$

For the AED model, in order to match the training procedure we must process each block in its entirety (including context) and provide the correct token history.

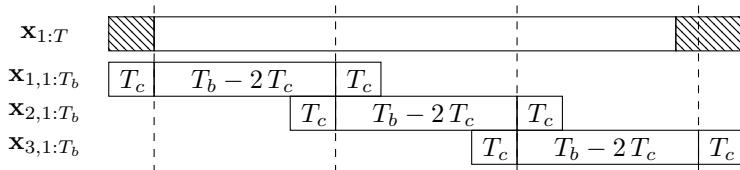


Fig. 1. Splitting input sequence into blocks. Here, the T_c is the context length, T_b is the block length. The hatching denotes the padding added to the input sequence

First, we define the AED probability for an alignment $a_{1:t}$ instead of a token sequence $u_{1:l}$:

$$P_{AED}(a_{1:t} | \mathbf{h}_{1:T}) = \prod_{t'=1}^t P_{AED}(a_{t'} | a_{1:t'-1}, \mathbf{h}_{1:T}), \quad (4)$$

where

$$P_{AED}(a_t | a_{1:t-1}, \mathbf{h}_{1:T}) = \begin{cases} P_{AED}(u_l | u_{1:l-1}, \mathbf{h}_{1:T}), & a_t \neq \epsilon, a_t \neq a_{t-1} \\ \text{where } u_{1:l} = \mathcal{B}(a_{1:t}) & \\ 1 & \text{otherwise} \end{cases}.$$

With this definition, it is holds that:

$$P_{AED}(u_{1:l}|\mathbf{h}_{1:T}) = P_{AED}(a_{1:t}|\mathbf{h}_{1:T}) \text{ for } a_{1:t} = \mathcal{A}_t(u_{1:l}),$$

where $\mathcal{A}_t : \mathcal{U}^l \rightarrow \mathcal{U}_e^t$ is an alignment function, that provides a valid CTC alignment $a_{1:t}$ for given tokens $u_{1:l}$, i.e., $\mathcal{A}_t(u_{1:l}) \in \mathcal{B}^{-1}(u_{1:l})$. Thus, the AED probability is tied to a particular decoding time step.

Next, we split $a_{1:T}$ into overlapping blocks $\{a_{b,1:T_b}\}_{b=1}^B$ in the same manner as described for the input sequence. For the overlapping part, the following holds: $a_{b-1,T_b-2T_c+t} = a_{b,t}$, $t \in [1, 2T_c]$. Substituting the concatenation into 4 yields:

$$a_{1:T} = [a_{1,T_c:T_b-T_c}, a_{2,T_c:T_b-T_c}, \dots, a_{B,T_c:T_b-T_c}],$$

$$\begin{aligned} & P_{AED}(u_{1:l}|\{\mathbf{h}_{b',1:T_b}\}_{b=1}^b) \\ &= P_{AED}(\{a_{b',1+T_c:T_b-T_c}\}_{b'=1}^{b-1}, a_{b,1:t}|\{\mathbf{h}_{b',1:T_b}\}_{b=1}^b) \\ &= \prod_{b'=1}^{b-1} \prod_{t'=1+T_c}^{T_b-T_c} P_{AED}(a_{b',t'}|a_{b',1:t'-1}, \mathbf{h}_{b',1:T_b}) \\ & \quad \cdot \prod_{t'=1+T_c}^t P_{AED}(a_{b,t'}|a_{b,1:t'-1}, \mathbf{h}_{b,1:T_b}). \end{aligned} \quad (5)$$

Here, each token is predicted by the AED model using the embeddings and history corresponding to the appropriate block.

The full score is computed at each step as:

$$P_{b,t}(u_{1:l}) = P_{CTC}(u_{1:l}|\{\mathbf{h}_{b',1:T_b}\}_{b'=1}^{b-1}, \mathbf{h}_{b,1:t}) \cdot P_{AED}(u_{1:l}|\{\mathbf{h}_{b',1:T_b}\}_{b=1}^b)^\alpha,$$

using Eqs. (3) and (5). These equations are expressed in a form where the tokens $u_{1:l}$ are estimated using only the first b blocks, forming the foundation for streaming blockwise decoding algorithm.

2.3. Blockwise scoring computation scheme. The CTC decoding algorithm and, therefore, i-sync decoding algorithm are based on the recursive scheme for CTC forward probability calculation [2]. This scheme for blockwise

scenario can be formulated with respect to Eq. (3). Let the forward probability variable be:

$$\gamma_{b,t}(u_{1:l}) = P_{CTC}(u_{1:l} | \{\mathbf{h}_{b',1:T_b}\}_{b'=1}^{b-1}, \mathbf{h}_{b,1:t}).$$

It can be computed recursively using auxiliary variables $\gamma_{b,t}^{\epsilon}(u_{1:l})$ and $\gamma_{b,t}^{\bar{\epsilon}}(u_{1:l})$:

$$\gamma_{b,t}(u_{1:l}) = \gamma_{b,t}^{\epsilon}(u_{1:l}) + \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}), \quad (6)$$

$$\gamma_{b,t}^{\epsilon}(u_{1:l}) = P_{CTC}(\epsilon | \mathbf{h}_{b,t}) \cdot (\gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) + \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1})), \quad (7)$$

$$\gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) = P_{CTC}(u_l | \mathbf{h}_{b,t}) \cdot (\gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) + \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) + \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l})), \quad (8)$$

where the time index t runs from $1 + T_c$ to $T_b - T_c$ and the block index b is going from 1 to B . This way, each block is processed one by one except contexts. To provide the glue between blocks, we set:

$$\gamma_{b,T_c}^{\epsilon}(u_{1:l}) = \gamma_{b-1,T_b-T_c}^{\epsilon}(u_{1:l}) \text{ and } \gamma_{b,T_c}^{\bar{\epsilon}}(u_{1:l}) = \gamma_{b-1,T_b-T_c}^{\bar{\epsilon}}(u_{1:l}),$$

with the initial conditions:

$$\gamma_{1,T_c}^{\epsilon}(u_{1:0}) = 1 \text{ and } \gamma_{1,T_c}^{\bar{\epsilon}}(u_{1:0}) = 0.$$

An alignment $\mathcal{A}_{b,t}(u_{1:l})$, corresponding to the t -th frame of the b -block, can be constructed via a recursive backtracing procedure. It follows the previous scheme in Eqs. (6)-(8):

$$\mathcal{A}_{b,t}(u_{1:l}) = \begin{cases} \mathcal{A}_{b,t}^{\epsilon}(u_{1:l}), & \gamma_{b,t}^{\epsilon}(u_{1:l}) \geq \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \\ \mathcal{A}_{b,t}^{\bar{\epsilon}}(u_{1:l}), & \gamma_{b,t}^{\epsilon}(u_{1:l}) < \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (9)$$

$$\mathcal{A}_{b,t}^{\epsilon}(u_{1:l}) = \begin{cases} \mathcal{A}_{b,t-1}^{\epsilon}(u_{1:l}) \oplus \epsilon, & \gamma_{b,t-1}^{\epsilon}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \\ \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \oplus \epsilon, & \gamma_{b,t-1}^{\epsilon}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (10)$$

$$\mathcal{A}_{b,t}^{\bar{\epsilon}}(u_{1:l}) = \begin{cases} \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \oplus u_l, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \\ \mathcal{A}_{b,t-1}^{\epsilon}(u_{1:l-1}) \oplus u_l, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \text{ and} \\ & \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \\ \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \oplus u_l, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \text{ and} \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \geq \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \end{cases}, \quad (11)$$

where the symbol \oplus denotes the concatenation of an alignment and a token. Time index t and block index b have the same ranges as in the forward probability scheme. Each alignment is associated with its corresponding forward probability: $\mathcal{A}_{b,t}^{\epsilon}(u_{1:l}) \sim \gamma_{b,t}^{\epsilon}(u_{1:l})$ and $\mathcal{A}_{b,t}^{\bar{\epsilon}}(u_{1:l}) \sim \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l})$. At each time step, the alignment is extended from the preceding alignment associated with the highest forward probability. The glue between blocks is maintained analogously forward probabilities:

$$\mathcal{A}_{b,T_c}^{\epsilon}(u_{1:l}) = \mathcal{A}_{b-1,T_b-T_c}^{\epsilon}(u_{1:l}) \text{ and } \mathcal{A}_{b,T_c}^{\bar{\epsilon}}(u_{1:l}) = \mathcal{A}_{b-1,T_b-T_c}^{\bar{\epsilon}}(u_{1:l}),$$

as well as the initial values, that are:

$$\mathcal{A}_{1,T_c}^{\epsilon}(u_{1:0}) = \emptyset \text{ and } \mathcal{A}_{1,T_c}^{\bar{\epsilon}}(u_{1:0}) = \emptyset.$$

Combining the time alignment computation scheme in Eqs. (9)-(11) with Eq. (5), we define a recursive scheme for the AED probabilities.

Let

$$\phi_{b,t}(u_{1:l}) = P_{AED}(\{a_{b',1+T_c:T_b-T_c}\}_{b'=1}^{b-1}, a_{b,1:t} | \{\mathbf{h}_{b',1:T_b}\}_{b=1}^b),$$

then

$$\phi_{b,t}(u_{1:l}) = \begin{cases} \phi_{b,t}^{\epsilon}(u_{1:l}), & \gamma_{b,t}^{\epsilon}(u_{1:l}) \geq \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \\ \phi_{b,t}^{\bar{\epsilon}}(u_{1:l}), & \gamma_{b,t}^{\epsilon}(u_{1:l}) < \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (12)$$

$$\phi_{b,t}^{\epsilon}(u_{1:l}) = \begin{cases} \phi_{b,t-1}^{\epsilon}(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^{\epsilon}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \\ \phi_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^{\epsilon}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (13)$$

$$\phi_{b,t}^{\bar{\epsilon}}(u_{1:l}) = \begin{cases} \phi_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \text{ and} \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \\ \phi_{b,t-1}^{\epsilon}(u_{1:l-1}) \cdot & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \text{ and} \\ P_{AED}(u_l | a_{b,1:t-1}^{\epsilon}, \mathbf{h}_{b,1:T_b}) \cdot & \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}), \\ \phi_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \cdot & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \text{ and} \\ P_{AED}(u_l | a_{b,1:t-1}^{\bar{\epsilon}}, \mathbf{h}_{b,1:T_b}) \cdot & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \geq \gamma_{b,t-1}^{\epsilon}(u_{1:l-1}) \end{cases}, \quad (14)$$

where $a_{b,1:t-1}^{\epsilon}$ and $a_{b,1:t-1}^{\bar{\epsilon}}$ are obtained as the last $t-1$ elements of $\mathcal{A}_{b,t-1}^{\epsilon}(u_{l-1})$ and $\mathcal{A}_{b,t-1}^{\bar{\epsilon}}(u_{l-1})$, respectively. Again, for the glue between blocks

$$\phi_{b,T_c}^{\epsilon}(u_{1:l}) = \phi_{b-1,T_b-T_c}^{\epsilon}(u_{1:l}) \text{ and } \phi_{b,T_c}^{\bar{\epsilon}}(u_{1:l}) = \phi_{b-1,T_b-T_c}^{\bar{\epsilon}}(u_{1:l}),$$

and the initial values are:

$$\phi_{1,T_c}^{\epsilon}(u_{1:0}) = 1 \text{ and } \phi_{1,T_c}^{\bar{\epsilon}}(u_{1:0}) = 1.$$

The final decoding procedure is described in Algorithm 1. It is almost classic i-sync decoding procedure Eqs. (6)-(8). It differs only in special procedure for AED score estimation, which is built on Eqs. (12)-(14). AED score estimation is the proposed novel part of i-sync decoding and is presented in Algorithm 2.

At each step of Algorithm 1, a hypothesis set $\Omega_{b,t}$ is formed by expanding the hypotheses from the previous step. The forward probabilities of the hypotheses are calculation along with expansion. At the end of each step the full score $P_{b,t}(u_{1:l})$ is calculated. After the final step, the best hypothesis, denoted \tilde{h} , is obtained.

Algorithm 1. Blockwise input-synchronous decoding

```

1:  $\Omega_{0,T_c} \leftarrow \{\{\}\}$  ▷ initialize with empty hypothesis
2:  $\gamma_{0,T_c}^\epsilon(\{\}) \leftarrow 1$ ;  $\gamma_{0,T_c}^{\bar{\epsilon}}(\{\}) \leftarrow 0$ 
3:  $\phi_{0,T_c}^\epsilon(\{\}) \leftarrow 1$ ;  $\phi_{0,T_c}^{\bar{\epsilon}}(\{\}) \leftarrow 1$ 
4: for  $b = 1, \dots, B$  do
5:   for  $t = 1 + T_c, \dots, T_b - T_c$  do
6:      $\Omega_{b,t} \leftarrow \emptyset$ 
7:     for  $g \in \Omega_{b,t-1}$  do
8:       for  $a \in U \cup \{\epsilon\}$  do
9:         if  $a = \epsilon$  then
10:           $\gamma_{b,t}^\epsilon(g) \leftarrow P_{CTC}(a|\mathbf{h}_t) \cdot (\gamma_{b,t-1}^\epsilon(g) + \gamma_{b,t-1}^{\bar{\epsilon}}(g))$ 
11:           $\Omega_{b,t} \leftarrow \cup \{g\}$ 
12:          continue
13:        end if
14:         $h \leftarrow g \oplus a$  ▷ build a new hypothesis  $h$  by concatenating  $g$  and  $a$ 
15:        if  $a = g_{-1}$  then ▷  $g_{-1}$  is the last symbol of  $g$ 
16:           $\gamma_{b,t}^{\bar{\epsilon}}(g) \leftarrow P_{CTC}(a|\mathbf{h}_t) \cdot \gamma_{b,t-1}^{\bar{\epsilon}}(g)$ 
17:           $\gamma_{b,t}^{\bar{\epsilon}}(h) \leftarrow P_{CTC}(a|\mathbf{h}_t) \cdot \gamma_{b,t-1}^\epsilon(g)$ 
18:        else
19:           $\gamma_{b,t}^{\bar{\epsilon}}(h) \leftarrow P_{CTC}(a|\mathbf{h}_t) \cdot (\gamma_{b,t-1}^\epsilon(g) + \gamma_{b,t-1}^{\bar{\epsilon}}(g))$ 
20:        end if
21:        if  $h \notin \Omega_{b,t-1}$  then
22:           $\gamma_{b,t}^\epsilon(h) \leftarrow P_{CTC}(\epsilon|\mathbf{h}_t) \cdot (\gamma_{b,t-1}^\epsilon(h) + \gamma_{b,t-1}^{\bar{\epsilon}}(h))$ 
23:           $\gamma_{b,t}^{\bar{\epsilon}}(h) \leftarrow P_{CTC}(a|\mathbf{h}_t) \cdot \gamma_{b,t-1}^\epsilon(h)$ 
24:        end if
25:         $\Omega_{b,t} \leftarrow \cup \{h\}$ 
26:      end for
27:    end for
28:    for  $h \in \Omega_{b,t}$  do ▷ score the hypothesis set
29:       $\phi_{b,t}(h) \leftarrow \text{AEDScoreEstimation}(h)$ 
30:       $P_{b,t}(h) \leftarrow (\gamma_{b,t}^\epsilon(h) + \gamma_{b,t}^{\bar{\epsilon}}(h)) \cdot (\phi_{b,t}(h))^\alpha$ 
31:    end for
32:     $\Omega_{b,t} \leftarrow \text{Pruning}(\Omega_{b,t})$  ▷ prune the hypothesis set
33:  end for
34:  for  $h \in \Omega_{b,t}$  do ▷ initialize values for the next block
35:     $\gamma_{b+1,T_c}^\epsilon(h) \leftarrow \gamma_{b,T_b-T_c}^\epsilon(h)$ ;  $\gamma_{b+1,T_c}^{\bar{\epsilon}}(h) \leftarrow \gamma_{b,T_b-T_c}^{\bar{\epsilon}}(h)$ 
36:     $\phi_{b+1,T_c}^\epsilon(h) \leftarrow \phi_{b,T_b-T_c}^\epsilon(h)$ ;  $\phi_{b+1,T_c}^{\bar{\epsilon}}(h) \leftarrow \phi_{b,T_b-T_c}^{\bar{\epsilon}}(h)$ 
37:  end for
38: end for
39:  $\tilde{h} \leftarrow \arg \max_{h \in \Omega_{B,T_b-T_c}} P_{B,T_b-T_c}(h)$ 

```

Algorithm 2. AED score estimation for blockwise input-synchronous decoding

```
1: if  $\gamma_{b,t-1}^\epsilon(h) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(h)$  then
2:    $\mathcal{A}_{b,t}^\epsilon(h) \leftarrow \mathcal{A}_{b,t-1}^\epsilon(h) \cdot \epsilon$ 
3:    $\phi_{b,t}^\epsilon(h) \leftarrow \phi_{b,t-1}^\epsilon(h)$ 
4: else
5:    $\mathcal{A}_{b,t}^\epsilon(h) \leftarrow \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(h) \cdot \epsilon$ 
6:    $\phi_{b,t}^\epsilon(h) \leftarrow \phi_{b,t-1}^{\bar{\epsilon}}(h)$ 
7: end if
8: if  $\gamma_{b,t-1}^{\bar{\epsilon}}(h) < \gamma_{b,t-1}^\epsilon(g)$  or  $\gamma_{b,t-1}^{\bar{\epsilon}}(h) < \gamma_{b,t-1}^{\bar{\epsilon}}(g)$  then
9:   if  $\gamma_{b,t-1}^\epsilon(g) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(g)$  then
10:     $\mathcal{A}_{b,t}^\epsilon(h) \leftarrow \mathcal{A}_{b,t-1}^\epsilon(g) \cdot a$ 
11:     $a_{b,1:t-1}^\epsilon \leftarrow$  last  $t-1$  frames of  $\mathcal{A}_{b,t-1}^\epsilon$ 
12:     $\phi_{b,t}^\epsilon(h) \leftarrow \phi_{b,t-1}^\epsilon(g) \cdot P_{AED}(a|a_{b,1:t-1}^\epsilon, \mathbf{h}_{b,1:T_b})$ 
13:   else
14:      $\mathcal{A}_{b,t}^{\bar{\epsilon}}(h) \leftarrow \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(g) \cdot a$ 
15:      $a_{b,1:t-1}^{\bar{\epsilon}} \leftarrow$  last  $t-1$  frames of  $\mathcal{A}_{b,t-1}^{\bar{\epsilon}}$ 
16:      $\phi_{b,t}^{\bar{\epsilon}}(h) \leftarrow \phi_{b,t-1}^{\bar{\epsilon}}(g) \cdot P_{AED}(a|a_{b,1:t-1}^{\bar{\epsilon}}, \mathbf{h}_{b,1:T_b})$ 
17:   end if
18: else
19:    $\mathcal{A}_{b,t}^{\bar{\epsilon}}(h) \leftarrow \mathcal{A}_{b,t-1}^{\bar{\epsilon}}(h) \cdot a$ 
20:    $\phi_{b,t}^{\bar{\epsilon}}(h) \leftarrow \phi_{b,t-1}^{\bar{\epsilon}}(h)$ 
21: end if
22: if  $\gamma_{b,t}^\epsilon(h) \geq \gamma_{b,t}^{\bar{\epsilon}}(h)$  then
23:    $\phi_{b,t}(h) \leftarrow \phi_{b,t}^\epsilon(h)$ 
24: else
25:    $\phi_{b,t}(h) \leftarrow \phi_{b,t}^{\bar{\epsilon}}(h)$ 
26: end if
```

2.4. An optimization of the blockwise scoring computation scheme.

In a real-world implementation of the proposed scheme for a Transformer-based CTC-AED model, the two model states are stored for each hypothesis h . A model state typically includes a key-value cache for each attention layer in the decoder, requiring a significant amount of memory. This key-value cache contains precomputed values for each token in the history. The first state corresponds to the history in $\mathcal{A}_{b,t}^\epsilon(h)$, and the second corresponds to the history in $\mathcal{A}_{b,t}^{\bar{\epsilon}}(h)$ (Eq. (14)). This can be optimized by keeping only one state per hypothesis.

The alignment backtracing can be simplified to maintain only a single alignment per time step, as follows:

$$\mathcal{A}_{b,t}(u_{1:l}) = \begin{cases} \mathcal{A}_{b,t}^\epsilon(u_{1:l}), & \gamma_{b,t}^\epsilon(u_{1:l}) \geq \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \\ \mathcal{A}_{b,t}^{\bar{\epsilon}}(u_{1:l}), & \gamma_{b,t}^\epsilon(u_{1:l}) < \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (15)$$

$$\mathcal{A}_{b,t}^\epsilon(u_{1:l}) = \mathcal{A}_{b,t-1}(u_{1:l}) \oplus \epsilon, \quad (16)$$

$$\mathcal{A}_{b,t}^{\bar{\epsilon}}(u_{1:l}) = \begin{cases} \mathcal{A}_{b,t-1}(u_{1:l}) \oplus u_l, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^\epsilon(u_{1:l-1}) \text{ and} \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \\ \mathcal{A}_{b,t-1}(u_{1:l-1}) \oplus u_l, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^\epsilon(u_{1:l-1}) \text{ or} \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \end{cases}. \quad (17)$$

Substituting of Eq. (15) into Eq. (16) yields Eq. (10), therefore, in this respect, the two alignment schemes are the same. Meanwhile, substituting Eq. (15) into Eq. (17) produces a result different from Eq. (11). When $\gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^\epsilon(u_{1:l-1})$ and $\gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1})$ but $\gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \leq \gamma_{b,t-1}^\epsilon(u_{1:l})$ the $\mathcal{A}_{b,t-1}^\epsilon(u_{1:l})$ is chosen for extension instead of $\mathcal{A}_{b,t-1}^{\bar{\epsilon}}(u_{1:l})$. This situation leads to token duplication but is considered to be very rare.

For this simplified alignment, an approximate AED score computation scheme is defined as follows:

$$\phi_{b,t}(u_{1:l}) = \begin{cases} \phi_{b,t}^\epsilon(u_{1:l}), & \gamma_{b,t}^\epsilon(u_{1:l}) \geq \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \\ \phi_{b,t}^{\bar{\epsilon}}(u_{1:l}), & \gamma_{b,t}^\epsilon(u_{1:l}) < \gamma_{b,t}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (18)$$

$$\phi_{b,t}^\epsilon(u_{1:l}) = \begin{cases} \phi_{b,t-1}^\epsilon(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^\epsilon(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \\ \phi_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^\epsilon(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \end{cases}, \quad (19)$$

$$\phi_{b,t}^{\bar{\epsilon}}(u_{1:l}) = \begin{cases} \phi_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \cdot 1, & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^\epsilon(u_{1:l-1}) \text{ and} \\ & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) \geq \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \\ \phi_{b,t-1}^\epsilon(u_{1:l-1}) \cdot & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^\epsilon(u_{1:l-1}) \text{ or} \\ P_{AED}(u_l | a_{b,1:t-1}, \mathbf{h}_{b,1:T_b}) & \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l}) < \gamma_{b,t-1}^{\bar{\epsilon}}(u_{1:l-1}) \end{cases}, \quad (20)$$

where $a_{b,1:t-1}$ is obtained as the last $t - 1$ frames of $\mathcal{A}_{b,t-1}(u_{1:t-1})$. Within this scheme, only one model state needs to be stored, corresponding to the history in $\mathcal{A}_{b,t}$.

The simplified estimation for AED score, based on Eqs. (18)-(20), is described in Algorithm 3.

Algorithm 3. Simplified AED score estimation for blockwise input-synchronous decoding

```
1: if  $\gamma_{b,t}^\epsilon(h) \geq \gamma_{b,t}^\epsilon(h)$  then
2:    $\mathcal{A}_{b,t}(h) \leftarrow \mathcal{A}_{b,t-1}(h) \cdot \epsilon$ 
3:    $\phi_{b,t}(h) \leftarrow \phi_{b,t-1}(h)$ 
4: else
5:   if  $\gamma_{b,t-1}^\epsilon(h) \geq \gamma_{b,t-1}^\epsilon(g)$  and  $\gamma_{b,t-1}^\epsilon(h) \geq \gamma_{b,t-1}^\epsilon(g)$  then
6:      $\mathcal{A}_{b,t}(h) \leftarrow \mathcal{A}_{b,t-1}(h) \cdot a$ 
7:      $\phi_{b,t}(h) \leftarrow \phi_{b,t-1}(h)$ 
8:   else
9:      $\mathcal{A}_{b,t}(h) \leftarrow \mathcal{A}_{b,t-1}(g) \cdot a$ 
10:     $a_{b,1:t-1} \leftarrow$  last  $t - 1$  frames of  $\mathcal{A}_{b,t-1}(g)$ 
11:     $\phi_{b,t}(h) \leftarrow \phi_{b,t-1}(g) \cdot P_{AED}(a|a_{b,1:t-1}, \mathbf{h}_{b,1:T_b})$ 
12:  end if
13: end if
```

3. Experiments. This section presents a study of the proposed algorithm in different scenarios and conditions with the previously trained CTC-AED model. The first part describes the data used and the details of the CTC-AED model training. The second part presents the results of algorithm evaluation.

3.1. Experimental setup. For algorithm evaluation, a CTC-AED model was trained in-house using the EspNet toolkit [22]. The model consists of 12 UCONV-Conformer encoder blocks [23] and 6 Transformer decoder blocks [10]. Each block, in both the encoder and decoder, uses 8 attention heads, has a hidden dimension of 240 and a linear layer width of 1024. The total number of parameters in the model is 30 million. The model was trained for 100 epochs using the joint CTC-AED loss [8], the Adam optimizer, and a weight decay of 1e-6. A warm-up schedule [10] with a peak learning rate of 0.002 achieved at 15th epoch was applied. The acoustic features are 80-dimensional mel-scale log filter banks, calculated using a 25ms window and a 10ms shift. The model was trained to predict positional graphemes as target tokens.

The training dataset comprises approximately 540 hours of in-house Russian speech data collected from various domains. The model was evaluated

on six in-house test sets, also from diverse domains, all with a 16 kHz sampling rate. These test sets differ in their source and, consequently, their acoustic environments. The details and statistics of the data used are presented in Table 1. Most utterances in the training datasets are approximately 30 seconds long. The test datasets were selected to provide a variety of input lengths.

Table 1. Domain and amount of experimental data

Dataset	Domain	Num. samples	Duration			
			Total, h	Mean, s	Min, s	Max, s
Train	Mixed	60494	540.12	32.14	1.00	116.47
TS1	Mid-field, noisy	1125	2.15	6.87	3.10	15.00
TS1	Far-field, quiet	180	1.63	32.53	16.86	38.30
TT1	Telephone	415	3.17	27.50	2.14	30.00
TT2	Telephone	30	1.07	128.46	60.84	278.82
TT3	Telephone	104	4.03	139.34	19.00	488.69
TT4	Telephone	86	2.20	92.07	9.47	497.66

For decoding, a C++ implementation of the proposed algorithm was used. It incorporates the optimization described Section 2.4 and is therefore defined by Algorithms 1 and 3. Pruning in Algorithm 1 is implemented by retaining a fixed number of the best hypotheses. The number is referred to as beam size.

3.2. Results of evaluation. The first series of experiments were designated to estimate the model performance in terms of WER in non-streaming scenario. The results are presented in Table 2. A significant difference is observed between short-form datasets (TS1, TS2, TT1) and long-form datasets (TT2, TT3, TT4). For long-form datasets, the best WER is achieved at lower values of α , which suggests that AED predictions are not highly relevant for this case, especially for TT4. This is attributed to the poor ability of the AED model to generalize to audio that is long relative to the training dataset [11].

The second series of experiments estimates the model's WER in the blockwise streaming scenario. The block size was chosen to be 30 seconds, which is consistent with the train dataset. The results are shown in Table 3. A WER reduction of 2-2.5% (absolute) is observed for the long-form test datasets. The proper block size during decoding allows avoiding the long-form generalization issues. The WER on short-form datasets is close to the non-streaming scenario.

In addition, the optimal α values for all datasets are close to each other and grouped around 1.2-1.4. Thus, there is no need to tune α for long-form and short-form scenarios separately.

Table 2. WER in the non-streaming scenario as a function of α . This corresponds to the case, where T_b equals the length of the input audio. The bottom row shows the best WER for the given dataset achieved across all evaluated values of α

α	TS1	TS2	TT1	TT2	TT3	TT4	Mean
0.0	36.64	41.63	33.27	24.04	23.39	41.54	33.42
0.4	33.04	38.68	30.61	21.87	22.30	36.76	30.54
0.6	32.22	38.45	30.09	22.06	23.31	38.48	30.77
0.8	31.85	38.14	29.69	22.91	24.99	39.49	31.18
1.0	31.88	37.80	29.47	23.37	27.10	40.77	31.73
1.2	31.58	37.77	29.32	25.67	29.79	42.10	32.71
1.4	31.38	37.86	29.32	28.21	32.67	43.94	33.90
1.6	31.46	38.37	29.43	30.24	35.81	45.60	35.15
1.8	31.30	39.28	29.66	32.78	38.78	47.38	36.53
best	31.30	37.77	29.32	21.87	22.30	36.76	29.89

Table 3. WER in streaming scenario with the proposed algorithm. $T_b = 30$ s, $T_c = 1$ s. The bottom row shows the best WER achieved across all evaluated values of α

α	TS1	TS2	TT1	TT2	TT3	TT4	Mean
0.00	36.60	42.54	33.45	22.78	22.92	38.98	32.88
0.40	32.68	39.16	30.37	20.77	21.14	36.42	30.09
0.60	31.79	38.73	29.96	20.43	20.86	35.80	29.59
0.80	31.31	38.71	29.67	20.21	20.54	35.36	29.30
1.00	31.29	38.55	29.45	19.97	20.36	35.16	29.13
1.20	31.10	38.69	29.39	19.65	20.18	34.99	29.00
1.40	31.01	38.75	29.25	19.36	20.06	34.91	28.89
1.60	30.75	39.42	29.32	19.79	19.99	35.14	29.07
1.80	30.84	41.18	29.79	19.57	19.89	35.31	29.43
best	30.75	38.55	29.25	19.36	19.89	34.91	28.79

The third series of experiments investigates the dependence of WER on context size T_c and block size T_b . The results are presented in Tables 4 and 5. The model without contexts, i.e., without overlap between blocks, performs, on average, 0.5-0.6 % worse, compared to a model with a context of 1 second. Overlap helps to mitigate negative effects at block edges. Increasing contexts beyond 1 second does not have a noticeable effect on performance. Decreasing the size of a whole block leads to WER performance degradation. However, there is a trade-off between WER and computational cost, as the encoder and decoder have quadratic time and memory complexity with respect to the input length. For example, decreasing the block size from 30 to 20 seconds results in a noticeable speed-up at the cost of a 0.5 % WER degradation.

Table 4. WER for the streaming scenario with the proposed algorithm as a function of T_c (measured in seconds). The block size is fixed at $T_b = 30$ seconds. The AED weight is fixed at $\alpha = 1.2$

T_c	TS1	TS2	TT1	TT2	TT3	TT4	Mean
0.0	31.58	38.94	29.32	20.94	20.71	36.27	29.63
0.4	31.24	38.76	29.02	20.11	20.20	35.19	29.09
1.0	31.10	38.69	29.39	19.65	20.18	34.99	29.00
2.0	31.09	38.65	29.14	19.73	19.85	34.89	28.89

Table 5. WER for the streaming scenario with the proposed algorithm as a function of T_b (measured in seconds). The block context size is fixed at $T_c = 1$ second. The AED weight is fixed at $\alpha = 1.2$

T_b	TS1	TS2	TT1	TT2	TT3	TT4	Mean
30.00	31.10	38.69	29.39	19.65	20.18	34.99	29.00
26.00	31.14	38.96	29.44	19.87	20.23	34.92	29.09
20.00	31.69	39.25	29.80	20.51	20.06	35.12	29.41
0.0	31.58	38.94	29.32	20.94	20.71	36.27	29.63
8.00	33.25	40.75	31.34	28.34	20.98	36.95	31.94

Table 6 demonstrates WER, achieved with the proposed algorithm in different scenarios, in comparison with the baseline non-streaming o-sync¹ and i-sync² decoding algorithms from EspNet toolkit.

Table 6. Comparison of the proposed algorithm (in different modes) with the non-streaming decoding algorithms from EspNet in terms of WER. The AED weight is fixed at $\alpha = 1.2$

Decoding	TS1	TS2	TT1	TT2	TT3	TT4	Mean
EspNet O-Sync, non-streaming	39.58	38.94	31.14	29.41	33.421	44.70	36.20
EspNet I-Sync, non-streaming	34.79	38.34	29.40	26.79	30.37	44.91	34.10
Proposed, non-streaming ($T_b = \inf$, $T_c = 0$ s)	31.58	37.77	29.32	25.67	29.79	42.10	32.71
Proposed, streaming ($T_b = 30$ s, $T_c = 0$ s)	31.30	38.92	29.32	20.51	20.50	36.06	29.47
Proposed, streaming ($T_b = 30$ s, $T_c = 1$ s)	31.10	38.69	29.39	19.65	20.18	34.99	29.00

¹https://github.com/espnet/espnet/blob/v.202412/espnet/nets/beam_search.py

²https://github.com/espnet/espnet/blob/v.202412/espnet/nets/beam_search_timesync.py

All algorithms were run with similar settings and the same beam size of 15. In the non-streaming scenario, the proposed algorithm is close to the EspNet i-sync decoding, since they follow the same decoding scheme and differ only in implementation details. This also confirms the correctness of the studied algorithm's implementation.

4. Conclusion. This paper proposes a novel blockwise input-synchronous (i-sync) decoding algorithm for the CTC-AED model. In contrast to alternative streaming algorithms, it inherently supports arbitrary-length overlap between blocks and requires no modifications to the CTC-AED architecture or its training procedure. The presented experiments show that the proposed algorithm is able to retain WER performance close to non-streaming scenario on short-form test datasets and performs significantly better on long-form test datasets, thereby avoiding the length generalization problem. It is also shown that overlap has a positive effect on WER, leading to an average decrease of 0.5% and up to 2% in a long-form scenario.

References

1. Trentin E., Gori M. A survey of hybrid ANN/HMM models for automatic speech recognition. *Neurocomputing*. 2001. vol. 37. no. 1-4. pp. 91–126. DOI: 10.1016/S0925-2312(00)00308-8.
2. Graves A., Fernandez S., Gomez F., Schmidhuber J. Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks. *Proceedings of the 23rd international conference on Machine learning*. 2006. pp. 369–376. DOI: 10.1145/1143844.1143891.
3. Graves A., Mohamed A.-r., Hinton G. Speech recognition with deep recurrent neural networks. *IEEE International Conference on Acoustics, Speech and Signal Processing*. 2013. pp. 6645–6649. DOI: 10.1109/ICASSP.2013.6638947.
4. Chorowski J.K., Bahdanau D., Serdyuk D., Cho K., Bengio Y. Attention-based models for speech recognition. *Advances in neural information processing systems*. 2015. vol. 28.
5. Prabhavalkar R., Rao K., Sainath T.N., Li B., Johnson L., Jaitly N. A comparison of sequence-to-sequence models for speech recognition. *Proceedings of Interspeech*. 2017. pp. 939–943. DOI: 10.21437/Interspeech.2017-233.
6. Li B., Pang R., Sainath T.N., et al. Scaling end-to-end models for large-scale multilingual ASR. *IEEE Automatic Speech Recognition and Understanding Workshop (ASRU)*. 2021. pp. 1011–1018. DOI: 10.1109/ASRU51503.2021.9687871.
7. Kanda N., Ye G., Gaur Y., Wang X., Meng Z., Chen Z., Yoshioka T. End-to-end speaker-attributed ASR with transformer. *Proceedings of Interspeech*. 2021. pp. 4413–4417. DOI: 10.21437/Interspeech.2021-101.
8. Watanabe S., Hori T., Kim S., Hershey J.R., Hayashi T. Hybrid CTC/attention architecture for end-to-end speech recognition. *IEEE Journal of Selected Topics in Signal Processing*. 2017. vol. 11. no. 8. pp. 1240–1253. DOI: 10.1109/JSTSP.2017.2763455.
9. Yan B., Dalmia S., Higuchi Y., Neubig G., Metze F., Black A.W., Watanabe S. CTC alignments improve autoregressive translation. *Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics*. 2023. pp. 1623–1639. DOI: 10.18653/v1/2023.eacl-main.119.
10. Vaswani A., Shazeer N., Parmar N., et al. Attention is all you need. *Advances in Neural Information Processing Systems (NIPS 2017)*. 2017. vol. 30.

11. Chiu C.-C., Han W., Zhang Y., et al. A comparison of end-to-end models for long-form speech recognition. IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2019. pp. 889–896. DOI: 10.1109/ASRU46091.2019.9003854.
12. Varis D., Bojar O. Sequence length is a domain: Length-based overfitting in transformer models. Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. 2021. pp. 8246–8257. DOI: 10.18653/v1/2021.emnlp-main.650.
13. Chiu C.-C., Raffel C. Monotonic chunkwise attention. arXiv preprint arXiv:1712.05382. 2017.
14. Tsunoo E., Kashiwagi Y., Kumakura T., Watanabe S. Towards online end-to-end transformer automatic speech recognition. arXiv preprint arXiv: 1910.11871. 2019. DOI: 10.48550/arXiv.1910.11871.
15. Miao H., Cheng G., Zhang P., Yan Y. Online hybrid CTC/attention end-to-end automatic speech recognition architecture. IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2020. vol. 28. pp. 1452–1465. DOI: 10.1109/TASLP.2020.2987752.
16. Miao H., Cheng G., Gao C., Zhang P., Yan Y. Transformer-based online CTC/attention end-to-end speech recognition architecture. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020). 2020. pp. 6084–6088. DOI: 10.1109/ICASSP40776.2020.9053165.
17. Inaguma H., Mimura M., Kawahara T. Enhancing monotonic multihead attention for streaming ASR. Proceedings of Interspeech. 2020. pp. 2137–2141. DOI: 10.21437/Interspeech.2020-1780.
18. Moritz N., Hori T., Le J. Streaming automatic speech recognition with the transformer model. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020). 2020. pp. 6074–6078. DOI: 10.1109/ICASSP40776.2020.9054476.
19. Tsunoo E., Kashiwagi Y., Watanabe S. Streaming transformer asr with blockwise synchronous beam search. IEEE Spoken Language Technology Workshop (SLT). 2021. pp. 22–29. DOI: 10.1109/SLT48900.2021.9383517.
20. Tsunoo E., Narisetty C., Hentschel M., Kashiwagi Y., Watanabe S. Run-and-back stitch search: Novel block synchronous decoding for streaming encoder-decoder ASR. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2022). 2022. pp. 8287–8291. DOI: 10.1109/ICASSP43922.2022.9747800.
21. Zeineldeen M., Zeyer A., Schluter R., Ney H. Chunked attention-based encoderdecoder model for streaming speech recognition. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2024-2024). 2024. pp. 11331–11335. DOI: 10.1109/ICASSP48485.2024.10446035.
22. Watanabe S., Hori T., Karita S., Hayashi, T., Nishitoba, J., Unno, Y., Enrique Yalta Soplin, N., Heymann, J., Wiesner, M., Chen, N., Renduchintala, A., Ochiai, T. ESPNet: End-to-end speech processing toolkit. Proceedings of Interspeech. 2018. pp. 2207–2211. DOI: 10.21437/Interspeech.2018-1456.
23. Andrusenko A., Nasretdinov R., Romanenko A. Uconv-conformer: High reduction of input sequence length for end-to-end speech recognition. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2023-2023). 2023. pp. 1–5.

Lezhenin Iurii — PhD student, Speech and NLP Research Group, Institute of Computer Science, Peter the Great St. Petersburg Polytechnic University (SPbPU); Leading researcher, ASR team, Speech Technology Center LTD. Research interests: machine learning, digital signal processing (DSP), speech processing. The number of publications — 24. yuriy.lezhenin@gmail.com; 29B, Polytechnicheskaya St., 195220, St. Petersburg, Russia; office phone: +7(905)265-9788.

Bogach Natalia — Ph.D., Associate professor, Speech and NLP Research Group, Institute of Computer Science, Peter the Great St. Petersburg Polytechnic University (SPbPU). Research interests: digital signal processing (DSP), speech processing, linguistics. The number of publications — 29. n.v.bogach@gmail.com; 29B, Polytechnicheskaya St., 195220, St. Petersburg, Russia; office phone: +7(905)265-9788.

Ю.И. ЛЕЖЕНИН, Н.В. БОГАЧ

**БЛОЧНЫЙ АЛГОРИТМ ДЕКОДИРОВАНИЯ
С СИНХРОНИЗАЦИЕЙ ПО ВХОДУ ДЛЯ СТС-АЕД СИСТЕМ
РАСПОЗНАВАНИЯ РЕЧИ**

Леженин Ю.И., Богач Н.В. Блочный алгоритм декодирования с синхронизацией по входу для СТС-АЕД систем распознавания речи.

Аннотация. Для работы в реальных условиях от систем автоматического распознавания речи требуется обеспечивать стабильную точность распознавания при обработке входного аудиопотока произвольной длины в условиях ограниченных вычислительных ресурсов. Объединенная модель из коннекционистской темпоральной классификации (connectionist temporal classification, СТС) и кодировщик-декодировщика с механизмом внимания (attention-based encoder-decoder, АЕД) обеспечивают высокое качество распознавания, но исходная версия модели не удовлетворяет данным требованиям. В данной статье предлагается алгоритм блочного декодирования с синхронизацией по входу для совместной модели СТС-АЕД. Алгоритм обрабатывает перекрывающиеся блоки аудио синхронно относительно входной последовательности признаков, используя СТС-выравнивание для определения соответствующего контекста на перекрывающемся участке для АЕД декодировщика. Фиксированная длина блока обеспечивает предсказуемое и ограниченное потребление ресурсов и позволяет избежать проблем с обобщением на длинных речевых сегментах, в то время как перекрытие блоков снижает ухудшение качества распознавания, вызванное краевыми эффектами на границах блоков. В отличие от других алгоритмов декодирования для СТС-АЕД, предложенный алгоритм не требует ни модификации архитектуры модели, ни специальной процедуры обучения, и, в то же время, поддерживает перекрытие блоков. В работе также исследуется производительность предложенного алгоритма с точки зрения доли словесных ошибок (word error rate, WER) в зависимости от размера блока и размера перекрытия.

Ключевые слова: потоковое распознавание речи, блочное декодирование, сквозные модели, АЕД, СТС.

Литература

1. Trentin E., Gori M. A survey of hybrid ANN/HMM models for automatic speech recognition. *Neurocomputing*. 2001. vol. 37. no. 1-4. pp. 91–126. DOI: 10.1016/S0925-2312(00)00308-8.
2. Graves A., Fernandez S., Gomez F., Schmidhuber J. Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks. *Proceedings of the 23rd international conference on Machine learning*. 2006. pp. 369–376. DOI: 10.1145/1143844.1143891.
3. Graves A., Mohamed A.-r., Hinton G. Speech recognition with deep recurrent neural networks. *IEEE International Conference on Acoustics, Speech and Signal Processing*. 2013. pp. 6645–6649. DOI: 10.1109/ICASSP.2013.6638947.
4. Chorowski J.K., Bahdanau D., Serdyuk D., Cho K., Bengio Y. Attention-based models for speech recognition. *Advances in neural information processing systems*. 2015. vol. 28.
5. Prabhavalkar R., Rao K., Sainath T.N., Li B., Johnson L., Jaitly N. A comparison of sequence-to-sequence models for speech recognition. *Proceedings of Interspeech*. 2017. pp. 939–943. DOI: 10.21437/Interspeech.2017-233.

6. Li B., Pang R., Sainath T.N., et al. Scaling end-to-end models for large-scale multilingual ASR. IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2021. pp. 1011–1018. DOI: 10.1109/ASRU51503.2021.9687871.
7. Kanda N., Ye G., Gaur Y., Wang X., Meng Z., Chen Z., Yoshioka T. End-to-end speaker-attributed ASR with transformer. Proceedings of Interspeech. 2021. pp. 4413–4417. DOI: 10.21437/Interspeech.2021-101.
8. Watanabe S., Hori T., Kim S., Hershey J.R., Hayashi T. Hybrid CTC/attention architecture for end-to-end speech recognition. IEEE Journal of Selected Topics in Signal Processing. 2017. vol. 11. no. 8. pp. 1240–1253. DOI: 10.1109/JSTSP.2017.2763455.
9. Yan B., Dalmia S., Higuchi Y., Neubig G., Metze F., Black A.W., Watanabe S. CTC alignments improve autoregressive translation. Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics. 2023. pp. 1623–1639. DOI: 10.18653/v1/2023.eacl-main.119.
10. Vaswani A., Shazeer N., Parmar N., et al. Attention is all you need. Advances in Neural Information Processing Systems (NIPS 2017). 2017. vol. 30.
11. Chiu C.-C., Han W., Zhang Y., et al. A comparison of end-to-end models for long-form speech recognition. IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2019. pp. 889–896. DOI: 10.1109/ASRU46091.2019.9003854.
12. Varis D., Bojar O. Sequence length is a domain: Length-based overfitting in transformer models. Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. 2021. pp. 8246–8257. DOI: 10.18653/v1/2021.emnlp-main.650.
13. Chiu C.-C., Raffel C. Monotonic chunkwise attention. arXiv preprint arXiv:1712.05382. 2017.
14. Tsunoo E., Kashiwagi Y., Kumakura T., Watanabe S. Towards online end-to-end transformer automatic speech recognition. arXiv preprint arXiv: 1910.11871. 2019. DOI: 10.48550/arXiv.1910.11871.
15. Miao H., Cheng G., Zhang P., Yan Y. Online hybrid CTC/attention end-to-end automatic speech recognition architecture. IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2020. vol. 28. pp. 1452–1465. DOI: 10.1109/TASLP.2020.2987752.
16. Miao H., Cheng G., Gao C., Zhang P., Yan Y. Transformer-based online CTC/attention end-to-end speech recognition architecture. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020). 2020. pp. 6084–6088. DOI: 10.1109/ICASSP40776.2020.9053165.
17. Inaguma H., Mimura M., Kawahara T. Enhancing monotonic multihead attention for streaming ASR. Proceedings of Interspeech. 2020. pp. 2137–2141. DOI: 10.21437/Interspeech.2020-1780.
18. Moritz N., Hori T., Le J. Streaming automatic speech recognition with the transformer model. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020). 2020. pp. 6074–6078. DOI: 10.1109/ICASSP40776.2020.9054476.
19. Tsunoo E., Kashiwagi Y., Watanabe S. Streaming transformer asr with blockwise synchronous beam search. IEEE Spoken Language Technology Workshop (SLT). 2021. pp. 22–29. DOI: 10.1109/SLT48900.2021.9383517.
20. Tsunoo E., Narisetty C., Hentschel M., Kashiwagi Y., Watanabe S. Run-and-back stitch search: Novel block synchronous decoding for streaming encoder-decoder ASR. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2022). 2022. pp. 8287–8291. DOI: 10.1109/ICASSP43922.2022.9747800.
21. Zeinelddeen M., Zeyer A., Schluter R., Ney H. Chunked attention-based encoderdecoder model for streaming speech recognition. IEEE International Conference on Acoustics,

- Speech and Signal Processing (ICASSP 2024-2024). 2024. pp. 11331–11335. DOI: 10.1109/ICASSP48485.2024.10446035.
22. Watanabe S., Hori T., Karita S., Hayashi, T., Nishitoba, J., Unno, Y., Enrique Yalta Soplin, N., Heymann, J., Wiesner, M., Chen, N., Renduchintala, A., Ochiai, T. ESPnet: End-to-end speech processing toolkit. Proceedings of Interspeech. 2018. pp. 2207–2211. DOI: 10.21437/Interspeech.2018-1456.
23. Andrusenko A., Nasredinov R., Romanenko A. Uconv-conformer: High reduction of input sequence length for end-to-end speech recognition. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2023-2023). 2023. pp. 1–5.

Леженин Юрий Игоревич — аспирант, научная группа речевых технологий и обработки естественного языка, институт компьютерных наук и кибербезопасности, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ); ведущий научный сотрудник, команда распознавания речи, ООО «Центр Речевых Технологий». Область научных интересов: машинное обучение, цифровая обработка сигналов, обработка речи. Число научных публикаций — 24. yuri.lezhenin@gmail.com; улица Политехническая, 29Б, 195220, Санкт-Петербург, Россия; р.т.: +7(905)265-9788.

Богач Наталья Владимировна — канд. техн. наук, доцент, научная группа речевых технологий и обработки естественного языка, институт компьютерных наук и кибербезопасности, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ). Область научных интересов: цифровая обработка сигналов, обработка речи, лингвистика. Число научных публикаций — 29. n.v.bogach@gmail.com; улица Политехническая, 29Б, 195220, Санкт-Петербург, Россия; р.т.: +7(905)265-9788.

Н.П. Колмаков, А.Н. Голубинский

ОЦЕНКА ВЛИЯНИЯ БИТНОСТИ ЧИСЕЛ С ПЛАВАЮЩЕЙ ЗАПЯТОЙ НА ТОЧНОСТЬ РАСПОЗНАВАНИЯ ДИКТОРОВ

Колмаков Н.П., Голубинский А.Н. Оценка влияния битности чисел с плавающей запятой на точность распознавания дикторов.

Аннотация. В статье проводится анализ изменения точности распознавания личности по голосу при выделении разного количества бит на число с плавающей запятой (квантование) выходного тензора нейронной сети. Тензор характеризирует скрытое пространство нейронной сети, которое содержит скрытые признаки, используемые при решении задачи распознавания дикторов. Обычно, на каждое число выходного пространства выделяется тридцать два бита (выходной тензор, исследуемых методов содержит 512 чисел), поэтому для поддержки постоянно актуализируемой базы данных требуется большое количество памяти. Из-за этого, особый интерес представляет тип чисел с плавающей запятой – *minifloat*, позволяющий работать с численным представлением, на которые выделяются восемь, шесть или четыре бита. Для обеспечения полноты результатов исследования, выбраны три нейросетевых решения, показывающие лучшие результаты распознавания на тестовой выборке: CAM++, WavLM, ReDimNet. Модели обладают уникальными архитектурными особенностями, что позволяет оценить изменение точности распознавания дикторов при уменьшении битности в зависимости от используемого типа архитектуры нейронной сети. Точность распознавания оценивается с помощью точки пересечения ошибок первого и второго рода. При проведении оценки точности распознавания используется англоязычный набор данных VoxCeleb-1, по характеристикам содержащихся аудиозаписей соответствует небольшой базе данных биометрической системы. Актуальность представленного материала обусловлена возрастающим количеством научных работ, которые предлагают использовать голос в качестве верификационного ключа. Поэтому, при работе с большим набором биометрических данных необходимо выделять большие объёмы памяти как на жёстких дисках, так и ОЗУ. Современные базы данных постоянно актуализируются и расширяются, что приводит к увеличению необходимых ресурсов на её поддержку. Одним из возможных методов решения может являться применение операции квантования к выходному тензору нейронной сети. Однако, преждевременное уменьшение количества выделяемых бит на число в выходном тензоре может привести к значительному ухудшению качества распознавания, относительно базовой версии сети. Основным направлением исследования является минимизация ресурсов для поддержки биометрической системы без дополнительного обучения нейронной сети.

Ключевые слова: распознавание дикторов, нейронные сети, числа с плавающей запятой, квантование.

1. Введение. Решением задачи распознавания дикторов исследователи занимаются не одно десятилетие. Одним из основных критериев, предъявляемых биометрической системе, является выставление оптимального значения решающего порога, который обеспечивает низкие значения ошибок первого или второго рода [1]. В последнее время для решения задачи активно используются методы, базирующиеся на технологии машинного обучения, что негласно

ставит дополнительный критерий – проводить распознавание при минимизации ресурсов на поддержку базы данных и выполнения вычислений. Одним из возможных методов решения проблемы является выделение меньшего количества бит на числа выходного тензора нейронной сети (эмбеддинг) [2]. Перед проведением математических операций с числами необходимо их преобразовать в бинарный вид. Общепринятая методика описана в стандарте IEEE 754 [3], однако, существуют такие методы [4, 5], которые отличаются от стандарта (поэтому в них могут отсутствовать бесконечности и NaN, тогда максимальным или минимальным преобразованным числом будет являться верхнее или нижнее допустимое значение доступного диапазона). При формировании чисел выделяется три типа бит: S – знак (0 – если число положительное, 1 – если число отрицательное); E – экспонента (смещённая экспонента двоичного числа); M – мантисса (остаток мантиссы двоичного нормализованного числа). Общий математический способ преобразования десятичного числа в бинарный вид [3]:

$$F = (-1)^S \times 2^{E-2^{(b-1)}+1} \times \left(1 + \frac{M}{2^n}\right), \quad (1)$$

где b – количество бит, выделяемых на экспоненту; n – количество бит, выделяемых на мантиссу.

В машинном обучении используются различные типы чисел с плавающей запятой: float32, float16 и bfloat16, охватывающие большой диапазон чисел. Однако, появление моделей машинного обучения количество параметров, которых насчитывает десятки и сотни миллиардов привело к использованию более мощных вычислительных ресурсов и к увеличению времени обучения, что эквивалентно удорожанию всего процесса исследования. Использование minifloat – тип числа с плавающей запятой, на который выделяется восемь, шесть или четыре бита, может быть, одним из способов удешевления процесса. Математический вид преобразования числа в minifloat представлен в (2). При наличии значащих бит в экспоненте [6]:

$$F = (-1)^S \times 2^{E-B} \times \left(1 + 2^{-m} \times M\right), \quad (2)$$

где B – количество бит, выделенных на экспоненту в эмбеддинге; m – количество бит, выделенных на мантиссу в эмбеддинге.

При отсутствии значащих бит в экспоненте [6]:

$$F = (-1)^S \times 2^{1-B} \times (0 + 2^{-m} \times M). \quad (3)$$

Операция квантования может применяться в процессе обучения, что позволяет быстрее обучать модель. Нередко квантование применяют в процессе инференса, что позволяет запускать модели с большим количеством параметров на менее производительных аппаратных средствах, относительно используемых на этапе обучения. В задаче распознавания дикторов используются модели с количеством обучаемых параметров исчисляемыми десятками или сотнями миллионов. Выходной последовательностью рассматриваемых нейронных сетей является одномерный тензор с длиной 512, в котором на каждое число выделяется тридцать два бита. В работах [7 – 9] исследуется возможность сохранения точности распознавания дикторов при сжатии модели путём квантования весов нейронной сети. Результаты, представленные в работах, показывают, что для сохранения исходных значений качества распознавания, квантованные сети проходят через этап дополнительного обучения. Подобный подход ограничивает количество доступных для использования методов, т.к. не все они обладают инструкцией или необходимым кодовым сопровождением для проведения обучения. Поэтому, в статье рассмотрен вариант оценки изменения значений ошибок первого и второго рода при уменьшении количества бит, выделяемых на число выходного пространства сети, описывающего внутреннее представление нейронной сети. Использование чисел с меньшим количеством бит позволит существенно сократить объём базы данных с информацией о дикторах, что в свою очередь удешевляет поддержку биометрической базы данных. Целью работы является оценка SOTA нейросетевых методов распознавания дикторов и исследование возможности минимизации ресурсов, требуемых для постоянной поддержки биометрической системы без дополнительного и трудозатратного обучения нейронной сети.

2. Используемые типы чисел с плавающей запятой. Для работы с внутренним представлением нейронной сети используются несколько типов чисел с плавающими запятой.

Float32 (одинарная точность / полная точность) – тип числа с плавающей запятой, определён в стандарте IEEE 754, который

содержит восемь бит на экспоненту и двадцать три бита на мантиссу. Диапазон чисел с плавающей запятой находится на отрезке $\pm 3,4 \times 10^{38}$.

Float16 (полуточность) – тип числа с плавающей запятой, определён стандартом IEEE 754, который содержит пять бит на экспоненту и десять бит на мантиссу. Диапазон чисел, помещающихся в этот тип, находится на отрезке $\pm 6,55 \times 10^4$.

BFloat16 (brain floating point) – тип числа с плавающей запятой, представлен для эффективного вычисления на TPU [10], который содержит восемь бит на экспоненту и семь бит на мантиссу. Диапазон чисел для экспоненты практически эквивалентен одинарной точности.

Float8 (E5M2 и E4M3) – тип числа с плавающей запятой, minifloat, представлен в [6, 10, 11]. Для E5M2 – диапазон чисел $\pm 5,73 \times 10^4$. Для E4M3 – диапазон чисел $\pm 4,48 \times 10^2$.

Float6 (E3M2, E2M3) – тип чисел с плавающей запятой, minifloat, описан в [10]. E3M2 – диапазон чисел ± 28 . E2M3 – диапазон чисел $\pm 7,5$.

Float4 (E2M1) – тип чисел с плавающей запятой, minifloat описан в [6]. Принимает пятнадцать значений на отрезке ± 6 . $[-6; -4; -3; -2; -1,5; -1; -0,5; 0; 0,5; 1; 1,5; 2; 3; 4; 6]$.

На основе формул 1-3, представлен пример преобразования числа из полной точности в minifloat с выделением 4 бит на число (E=2). Возьмём число 4,5 (находится в допустимом диапазоне чисел float4), в бинарной полной точности представляется следующим образом 0100,1₂. Очевидно, что исходное число находится между двумя допустимыми значениями: 4 (B=2, m=0) и 6 (B=2, m=1). Поскольку, разность допустимых чисел и исходным составляет 0,5 и 2, соответственно, тогда исходное число примет то значение, которое обладает наименьшей разницей с ним, т.е. 4. По аналогии, число 5 будет так же преобразовано в число 4; другое число 5,1 будет преобразовано в 6. Остальные положительные числа, которые выходят за диапазон допустимого значения так же будут преобразованы в 6.

3. Тестовый набор данных. Оценка влияния битности эмбеддинга нейронной сети на изменение ошибок первого и второго рода, происходит на англоязычном наборе данных VoxCeleb - 1 [12] – содержит более ста тысяч аудиофайлов для семи тысяч дикторов, длина записи варьируется от 3 до 10 секунд, частота дискретизации записей 16 кГц с разрядностью 16 бит. Для проведения процесса верификации, разработчиками датасета составлены пары

аудиозаписей, в котором сочетаются аудиофайлы диктора самим с собой или с другими. Этот набор данных состоит из трёх наборов VoxCeleb-E – содержит 37611 пару записей без фонового шума, VoxCeleb-O – содержит 550894 пары записей без фонового шума, VoxCeleb-H – содержит 579818 пар записей с фоновым шумом, который аугментирован шумами разного рода. В таблице 1 представлены данные о количестве памяти, требуемой для хранения внутренних представлений сети для всех пар дикторов каждого набора данных при использовании различных типов чисел. В скобках указано число, показывающее на сколько, уменьшилось количество требуемых МБ на хранение квантованной базы данных относительно полной точности.

Таблица 1. Объём наборов данных VoxCeleb-1 при разном типе чисел с плавающей запятой

	Наборы данных		
	VoxCeleb-E, (МБ)	VoxCeleb-O, (МБ)	VoxCeleb-H, (МБ)
Float32	73,46	1075,96	1132,46
Float16	36,73 (↓36,73)	537,98 (↓537,98)	566,23 (↓566,23)
Float8	18,36 (↓55,09)	268,99 (↓806,97)	283,11 (↓849,34)
Float6	13,77 (↓59,69)	201,74 (↓874,22)	212,34 (↓920,12)
Float4	9,18 (↓64,28)	134,50 (↓941,47)	141,56 (↓990,90)

4. Методика оценки. Для оценки схожести между выходными тензорами нейронной сети до и после уменьшения количества бит используется метрика косинусного сходства:

$$\cos(\alpha) = \frac{(\vec{a}, \vec{b})}{|\vec{a}| \times |\vec{b}|}, \quad (4)$$

где $\cos(\alpha)$ – коэффициент косинусного сходства; \vec{a} , \vec{b} – векторное представление двух аудиозаписей; $|\vec{a}|$, $|\vec{b}|$ – евклидова норма векторов; (\vec{a}, \vec{b}) – скалярное произведение.

Оценка изменений показателей коэффициентов косинусного сходства осуществляется путём вычисления ошибок первого и второго рода и равновероятной ошибки. Математическое определение представлено:

$$EER|_{FAR=FRR} = FAR = FRR;$$

$$FAR = \frac{FP}{FP + TN};$$

$$FRR = \frac{FN}{FN + TP},$$
(5)

где EER – равновероятная ошибка, пересечение ошибок первого и второго рода; FAR – ошибка первого рода; FRR – ошибка второго рода; FP – ложно принятые записи; TP – верно принятые записи; TN – верно отвергнутые записи; FN – ложно отвергнутые записи.

При использовании различных типов чисел в выходном тензоре модели, значения ошибок первого и второго рода позволяют оценить тенденцию изменений значений метрики схожести относительно базовой версии сети. На рисунке 1 представлена схема, описывающая процесс оценки распознавания дикторов, которая используется в рамках исследования.

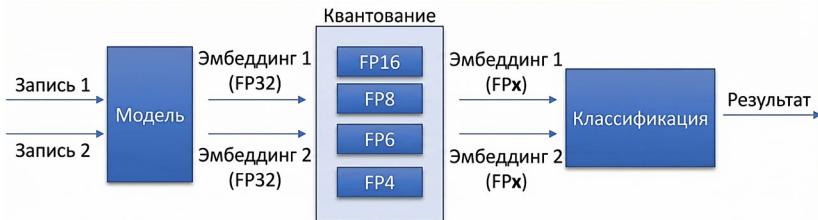


Рис. 1. Распознавание дикторов при разном типе чисел с плавающей запятой в эмбеддинге

Результатом классификации является коэффициент косинусного сходства, при сравнении со значением порога принимается решение о соответствии двух записей к одному и тому же диктору.

5. Context Aware Masking. CAM++ [13] – свёрточная нейронная сеть, которая содержит 7,2 миллиона параметров. Относится к моделям, которые работают с представлением диктора на базе х-вектора [14]. Для извлечения признаков из внутреннего пространства, десятисекундной записи, модели требуется 264,43 МБ видеопамяти. Опубликованная версия сети обучена на англоязычном наборе данных VoxCeleb-2 [15]. Разработчикамиложен код и необходимые инструкции для проведения дополнительного

обучения, однако доступное кодовое сопровождение предназначено для работы только с одним набором данных VoxCeleb-2.

Перед извлечением признаков, входной сигнал преобразовывают в блок фильтров с размером окна 25 мс и шагом 10 мс. Сформированный блок фильтров подаётся на модуль, состоящий из четырёх пропускающих блоков, которые используются для извлечения признаков по времени и частоте. Полученные признаки поступают на три последовательных модифицированных D-TDNN [16] блока. Каждый блок состоит из двух внутренних модулей CAM [17] и TDNN.

Для проведения оценки изменения ошибок первого и второго рода, произведен анализ распределений косинусных коэффициентов схожести между выходными тензорами нейронной сети до и после выделения различного количества бит на число. Первичная оценка влияния битности внутренних представлений осуществляется путём визуального анализа изменения графиков для разных типов чисел относительно полученных результатов для полной точности. Более широкие области графика соответствуют большему количеству коэффициентов косинусного сходства. Полученные результаты представлены на рисунке 2.

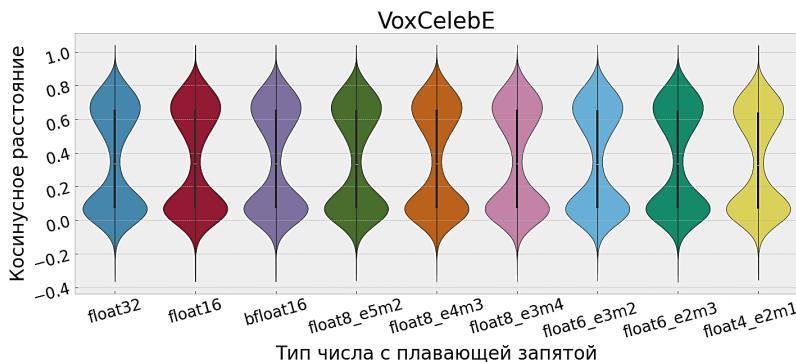


Рис. 2. Изменение разброса косинусного сходства при квантовании эмбеддинга CAM++

Из графика, представленного на рисунке 2, следует, что выделение меньшего количества бит на число выходного пространства CAM++ незначительно изменило общее распределение косинусных коэффициентов сходства. Полученные результаты позволяют сделать заключение об устойчивости эмбеддинга сети при проведении процедуры квантования. Подтверждением полученных выводов

являются данные, показатели ошибок первого и второго рода при значении решающего порога, представленного разработчиками метода, равного 0,381 [13]. Полученные результаты представлены в таблице 2. Возле каждого значения ошибки в таблице будет предоставлено условное обозначение: ↓ – если получившийся показатель улучшился, по сравнению полученными в полной точности, что привело к уменьшению ошибки; ↑ – если получившийся показатель ухудшился, по сравнению полученным в полной точности, что привело к увеличению метрики; или = – значит, что показатели метрик совпадают для обоих типов чисел и значения ошибки не изменился.

Таблица 2. Изменение ошибок первого и второго рода при квантовании внутреннего пространства CAM++

	Наборы данных					
	VoxCeleb-E		VoxCeleb-O		VoxCeleb-H	
	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)
Float32	0,93	3,61	1,39	2,94	3,86	3,47
Float16	0,93 (=)	3,61 (=)	1,39 (=)	2,94 (=)	3,86 (=)	3,47 (=)
BFloat16	0,93 (=)	3,61 (=)	1,39 (=)	2,94 (=)	3,86 (=)	3,47 (=)
Float8 e5m2	0,91 (↓0,02)	3,66 (↑0,05)	1,36 (↓0,03)	2,97 (↑0,03)	3,79 (↓0,02)	3,53 (↑0,08)
Float8 e4m3	0,93 (=)	3,62 (↑0,01)	1,37 (↓0,02)	2,95 (↑0,01)	3,84 (↓0,02)	3,49 (↑0,02)
Float8 e3m4	0,94 (↑0,01)	3,61 (=)	1,39 (=)	2,93 (↓0,01)	3,86 (=)	3,48 (↑0,01)
Float6 e3m2	0,91 (↓0,02)	3,67 (↑0,06)	1,36 (↓0,03)	2,97 (↑0,03)	3,79 (↓0,07)	3,53 (↑0,08)
Float6 e2m3	0,92 (↓0,01)	3,63 (↑0,02)	1,37 (↓0,02)	2,96 (↑0,02)	3,83 (↓0,03)	3,51 (↑0,04)
Float4 e2m1	0,80 (↓0,13)	4,10 (↑0,49)	1,19 (↓0,20)	3,29 (↑0,35)	3,37 (↓0,02)	3,95 (↑0,52)

Из данных представленных в таблице 2 следует, что значения ошибок первого и второго рода незначительно меняются, приблизительно, на 0,03% и 0,05% при использовании типов данных с восьмью или шестью битами; на 0,2% и 0,52% при выделении четырёх бит на число. Для получения детальной информации о влиянии квантования внутренних представлений нейронной сети на результаты распознавания дикторов, необходимо определить значения решающих порогов через нахождение равновероятной ошибки. Было замечено, что при оценке EER, обычно, графики ошибок первого и второго рода квантованных эмбеддингов практически совпадают с результатами,

полученными при использовании полной точности. Поэтому, в статье представлены только те результаты, в которых отклонение графиков ошибок визуально заметны. На рисунке 3 представлены графики пересечений ошибок первого и второго рода при использовании типа чисел данных `float4-e2m1` и `float32`.

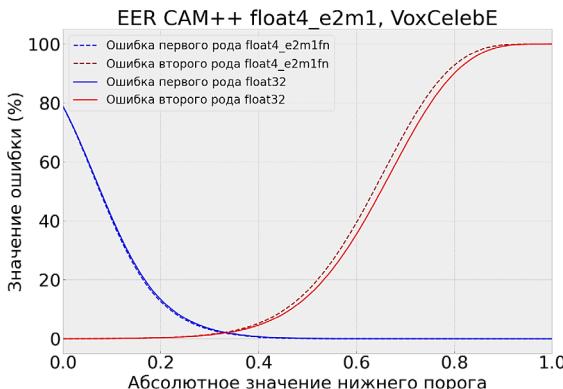


Рис. 3. Пересечение ошибок первого и второго рода при выделении четырёх бит на число для эмбеддинга CAM++

Из результатов, представленных на графике рисунка 3 следует, что при использовании `float4-e2m1` точка пересечения ошибок первого и второго рода совпадает с точкой, полученной при полной точности.

6. Reshape Dimensions Network. ReDimNet [18] – свёрточная нейронная сеть, отличительной особенностью, которой является извлечение уникальных речевых признаков диктора при комбинировании двух типов свёрточных слоёв: одномерного и двумерного. Модель содержит 5 миллионов параметров. Для извлечения признаков из внутреннего пространства, десятисекундной записи, требуется 4615,97 МБ видеопамяти. Потребление такого большого количества памяти по соотношению к малому количеству параметров, происходит из-за использования шести блоков многоголового внимания на каждый из них приходится по 663 МБ (используются тензоры с высокой размерностью в качестве основных компонентов внимания: ключ, значение, запрос). Опубликованная версия модели обучена на нескольких наборах данных VoxBlink-2 [19] и VoxCeleb-2. Разработчиками метода не выложена необходимая инструкция для обучения модели на новом языковом домене или наборе данных. На рисунке 4 представлен график для набора данных VoxCeleb-E в зависимости от количества выделенных бит на число в эмбеддинге.

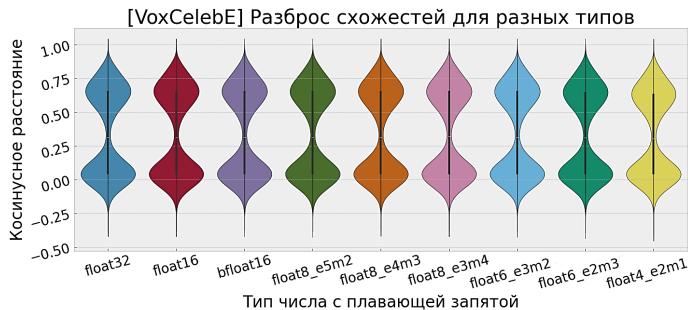


Рис. 4. Изменение разброса коэффициентов косинусного сходства при квантовании эмбеддинга ReDimNet

Из графика, представленного на рисунке 4, следует, что распределение коэффициентов косинусного сходства при выделении меньшего количества бит схоже с распределением при выделении тридцати двух бит. В таблице 3 представлены значения ошибок первого и второго рода при значении решающего порога равного 0,351, получен в ходе исследования.

Таблица 3. Изменение ошибок первого и второго рода при переквантовании внутреннего пространства ReDimNet

	Наборы данных					
	VoxCeleb-E		VoxCeleb-O		VoxCeleb-H	
	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)
Float32	1,57	0,41	2,59	0,19	4,97	0,42
Float16	1,57 (=)	0,41 (=)	2,52 (↓0,07)	0,19 (=)	4,97 (=)	0,42 (=)
BFloat16	1,57 (=)	0,41 (=)	2,61 (↑0,02)	0,19 (=)	4,97 (=)	0,42 (=)
Float8 e5m2	1,56 (↓0,01)	0,42 (↑0,01)	2,55 (↓0,04)	0,19 (=)	4,91 (↓0,06)	0,43 (↑0,01)
Float8 e4m3	1,57 (=)	0,41 (=)	2,58 (↓0,01)	0,18 (↓0,01)	4,96 (↓0,01)	0,43 (↑0,01)
Float8 e3m4	1,44 (↓0,13)	9,47 (↑9,06)	2,47 (↓0,12)	7,32 (↑7,13)	4,53 (↓0,44)	0,48 (↑0,06)
Float6 e3m2	1,56 (↓0,01)	0,42 (↑0,01)	2,55 (↓0,04)	0,19 (=)	4,91 (↓0,06)	0,43 (↑0,01)
Float6 e2m3	1,47 (↓0,10)	0,46 (↑0,05)	2,40 (↓0,19)	0,23 (↑0,04)	4,63 (↓0,34)	0,46 (↑0,04)
Float4 e2m1	1,32 (↓0,25)	0,56 (↑0,15)	2,17 (↓0,01)	0,34 (↑0,15)	4,17 (↓0,80)	0,55 (↑0,13)

По данным в таблице 3 видно, что изменение при выделении четырёх бит значение ошибки первого рода улучшилась на 0,32 %, значение ошибки второго рода ухудшилась на 0,15 %. В других случаях значения ошибок, практически, идентичны показателям ошибок, полученной в полной точности. На рисунке 5 представлен график пересечения ошибок первого и второго рода при выделении четырёх бит на число.

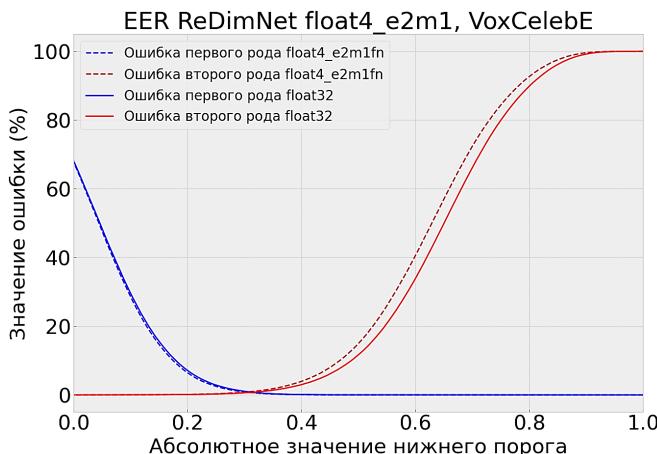


Рис. 5. Пересечение ошибок первого и второго рода при выделении четырёх бит на число для эмбеддинга ReDimNet

Из графика, представленного на рисунке 5, следует, что при выделении четырёх бит на число не приводит к сдвигу значения решающего порога, относительно базовой версии сети. Что соответствует использованию необходимого диапазона чисел каждого типа данных для сохранения исходных показателей качества распознавания.

7. WavLM. WavLM [20] – нейронная сеть, базирующаяся на архитектуре трансформер [21], содержит 100 миллионов параметров. Модель разработана для решения ряда задач: верификация дикторов, автоматическое распознавание речи, диаризация дикторов. Вторичной параметризацией речевого сигнала является блок фильтров с размером окна 25 мс и шагом 10 мс. Архитектурно модель делится на две сети: проецирующий вторичные признаки речевого сигнала во внутреннее пространство сети, состоит из семи свёрточных блоков (одномерная свёртка с функцией активации GELU [22]); аппроксиматор, который состоит из двенадцати блоков механизма внимания, архитектурно

является кодировщиком языковой модели. Для извлечения признаков из внутреннего пространства, десятисекундной записи, модели требуется 487,73 МБ видеопамяти. Рассматриваемая версия модели обучена на нескольких англоязычных наборах данных Libri-Light [23], GigaSpeech [24], VoxPopuli [25]. Разработчиками метода не выпущена необходимая инструкция для обучения модели на новый языковой домен или набор данных.

Процедура оценки распределения коэффициентов косинусного сходства при разных квантованиях выходного представлений модели аналогична предыдущему разделу. На рисунке 6 представлен соответствующий график.

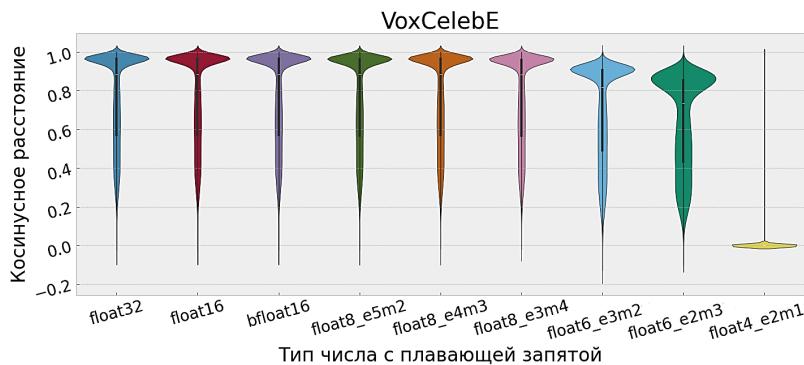


Рис. 6. Изменение разброса коэффициентов косинусного сходства при квантовании эмбеддинга WavLM

Из графика, представленного на рисунке 6, следует, что при выделении шести бит на число выходного тензора, наблюдается более выраженное распределение косинусных коэффициентов на отрезке от одного до нуля. При выделении четырёх бит на число большая часть коэффициентов косинусного сходства распределяется возле нуля, что свидетельствует об изменении положения точки пересечения ошибок первого и второго рода от 0,86 к 0,1. Подобное изменение распределения, позволяет сделать вывод об изменении решающего порога относительно базовой версии нейронной сети.

Информация об изменении ошибок первого и второго рода, при значении решающего порога, представленного разработчиками метода, 0,86 [20], продемонстрирована в таблице 4.

Таблица 4. Изменение ошибок первого и второго рода при квантовании внутреннего пространства WavLM

	Наборы данных					
	VoxCeleb-E		VoxCeleb-O		VoxCeleb-H	
	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)	FAR, (%)	FRR, (%)
Float32	4,57	1,10	6,23	2,96	2,01	1,04
Float16	4,57 (=)	1,10 (=)	6,23 (=)	2,96 (=)	2,01 (=)	1,04 (=)
BFloat16	4,57 (=)	1,10 (=)	6,23 (=)	2,95 (=)	2,01 (=)	1,04 (=)
Float8 e5m2	4,34 (↓0,17)	1,17 (↑0,07)	5,99 (↓0,24)	3,22 (↑0,26)	19,26 (↑17,25)	1,10 (↑0,06)
Float8 e4m3	4,10 (↓0,47)	1,12 (↑0,02)	6,14 (↓0,09)	3,04 (↑0,08)	19,90 (↑17,89)	1,05 (↑0,01)
Float8 e3m4	4,10 (↓0,47)	1,27 (↑0,17)	5,68 (↓0,55)	3,58 (↑0,62)	18,31 (↑15,35)	1,18 (↑0,14)
Float6 e3m2	0,05 (↓4,52)	9,60 (↑8,50)	1,10 (↓5,13)	22,83 (↑19,87)	3,20 (↑1,19)	9,20 (↑8,16)
Float6 e2m3	0,06 (↓4,51)	55,03 (↑54,07)	0,20 (↓6,03)	65,57 (↑62,61)	0,04 (↓1,97)	54,68 (↑53,64)
Float4 e2m1	0,04 (↓4,53)	97,55 (↑96,45)	0,0 (↓6,23)	99,63 (↑96,67)	0,01 (↓2,00)	97,54 (↑96,50)

По результатам, представленным в таблице 4, построены графики пересечения ошибок первого и второго рода при выделении четырёх бит на число эмбеддинга WavLM, рисунок 7.

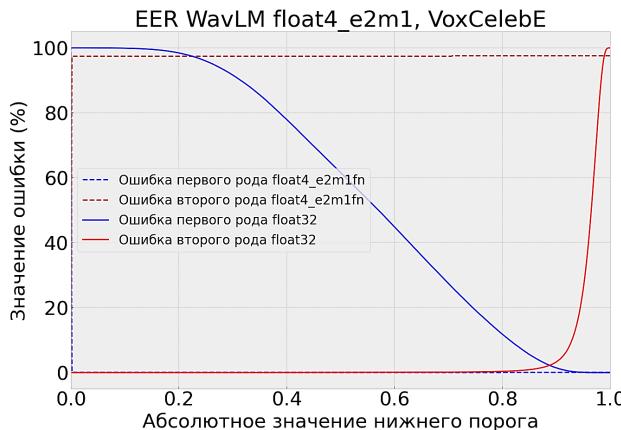


Рис. 7. Пересечение ошибок первого и второго рода при выделении четырёх бит на число для эмбеддинга WavLM

Из данных, представленных в таблице 4 и на рисунке 7, следует, что квантование выходного тензора WavLM во float4 привело к смещению пересечения ошибок первого и второго рода от 0,9 к 0. Подобный результат получен из-за использования недостаточного количества допустимых значений диапазона во float4, по сравнению с другими типами чисел. Однако, для CAM++ и ReDimNet не произошло сильных изменений относительно полной точности, поскольку используется необходимый диапазон значений в скрытом пространстве сети, для получения точности распознавания близкой к исходной версии сети.

Рассмотрим нормированный периодический сигнал с частотой дискретизации 16 кГц и длительностью две секунды, который содержит только два предельных значения -1 и 1. Синтезированный сигнал позволяет получить максимально допустимые значения выходного внутреннего пространства нейронной сети, соответствующие реальному речевому сигналу. При проведении анализа значений активаций нейросетевых моделей используются следующие показатели: максимального, минимального, среднего и стандартного отклонения. Структуры рассматриваемых сетей, на этапе обучения, можно обобщить тремя блоками: третичная параметризация, аппроксимация уникальных речевых признаков нейронной сетью, классификация (верификации дикторов из обучающей выборки). На этапе применения не используется блок классификации. Уникальные признаки речи, содержащиеся в скрытом пространстве нейронной сети, получают с одного из последних слоёв нейросетевого аппроксиматора. Несмотря на архитектурное различие сетей, у CAM++ и ReDimNet есть одна общая деталь, использование в составе последнего блока, слой нормализации мини-пакетов (batch normalization, BN) [26]. Поскольку, информация извлекается с последних слоёв аппроксиматора, целесообразно рассмотреть значения активаций до и после прохождения через слой BN. Дополнительно изучить показатели входного тензора.

Для входного тензора: 11,445; -15,942; 5,615; -12,437. Для CAM++, показатели в эмбеддинге равны: 0,179; -0,245; -0,002; 0,072 и 5,010; -6,509; -0,067; 1,979; до и после прохождение через слой BN, соответственно.

Для входного тензора: 1; -1; 0,333; 0,943. Для ReDimNet, показания в эмбеддинге равны: -3,639; 4,017; -0,229; 0,891 и -14,850; 14,575; 0,287; 4,875; до и после прохождение через слой BN, соответственно.

У WavLM в последних слоях не используется слой нормализации. Поэтому, рассмотрены значения активаций до и после прохождения через последний слой, значения которого используются для дальнейшей классификации. Для входного тензора: 1; -1; 0,943; 0,333. Для эмбеддинга получены следующие значения: 0; 0,274; 0,002; 0,014 и -0,316; 0,1790; -0,0289 до и после прохождения через последней слой сети.

По полученным результатам можно выдвинуть гипотезу об устойчивости квантованного эмбеддинга к квантованию в зависимости от составляющих блоков архитектуры нейронной сети. В состав архитектур CAM++ и ReDimNet входит ResNet блок, 4 и 17 соответственно. На рисунке 8 представлена структура блока.



Рис. 8. Структура ResNet блока

Если исследуемая архитектура содержит ResNet блоки, то диапазон значений выходного тензора после прохождения через последний BN будет достаточен для применения квантования, например, float4 без потери качества относительно значений эмбеддинга в полной точности. В других случаях необходимо провести дополнительную процедуру оценки выходного тензора из основного аппроксимирующего блока сети.

Поскольку, полученные результаты характерны только синтезированному сигналу. Проведено исследование для десяти тысяч выходных скрытых пространств, соответствующие реальным речевым сигналам, моделей CAM++ и WavLM при выделении тридцати двух и четырёх бит на число эмбеддинга. Для исследования полученных результатов квантованных чисел построены графики со значениями чисел внутреннего пространства нейронных сетей для float32 и float4. На рисунке 9 в пункте а) – представлены результаты квантования для CAM++, в пункте б) – представлены результаты квантования для WavLM.

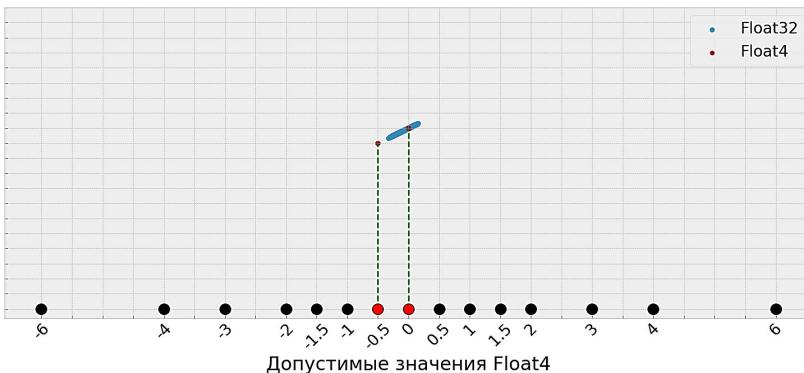
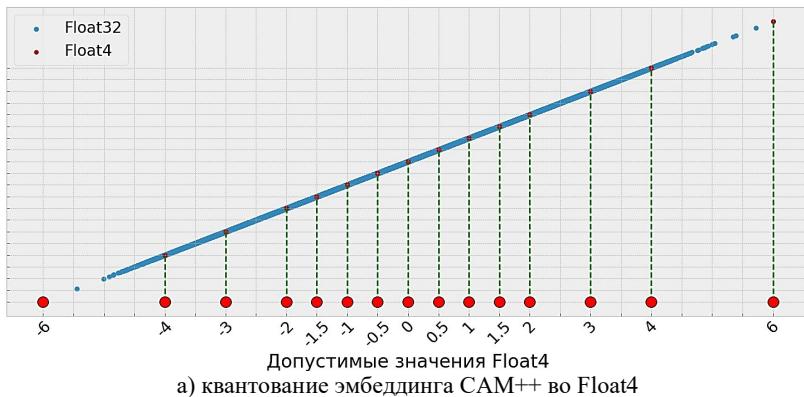


Рис. 9. Распределение значений эмбеддингов а) для CAM++ б) для WavLM при выделении 4 бит на число

Из результатов графиков, представленных на рисунке 9, следует, что в квантованном эмбеддинге CAM++ может содержаться весь доступный диапазон чисел во float4. Из-за того, что значения эмбеддингов для WavLM в полной точности лежат на отрезке от -0,4 до 0,25. Поэтому, в квантованном во float4 эмбеддинге содержатся только два числа -0,5 и 0, при применении метрики косинусного расстояния в большинстве случаев будет получен нулевой коэффициент схожести, что не соответствует исходным показателям, полученным в базовой версии сети. Для расширения используемого диапазона допустимых значений float4 необходимо воспользоваться процедурой масштабирования каждого числа в выходном тензоре (E_s):

$$E_s = \frac{F_{\max}}{E_{\max}} \times E, \quad (6)$$

где F_{\max} – максимальное допустимое значение во float4; E_{\max} – максимальное значение в эмбеддинге; E – эмбеддинг WavLM (одномерный тензор с размерностью 512).

На рисунке 10 представлены графики пересечений ошибок первого и второго рода до и после проведения операции масштабирования.

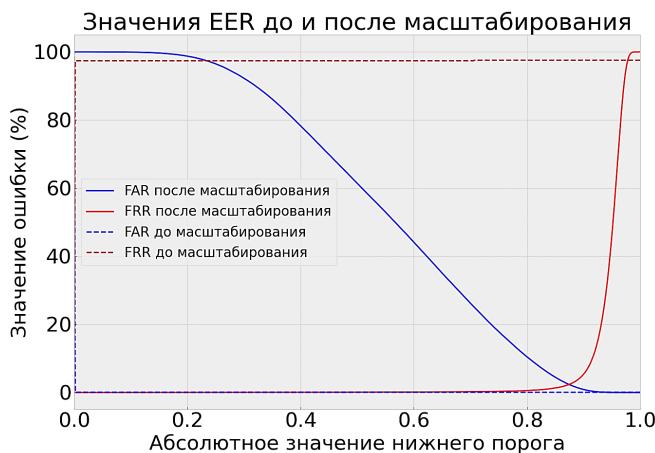


Рис. 10. Пересечение ошибок первого и второго рода до и после масштабирования для эмбеддинга WavLM

Из графика, представленного на рисунке 10, следует, что после применения операции масштабирования изменились значения ошибок первого и второго рода с 0,035% и 97,55 % до 3,5 % и 1,6 %, при исходном значении решающего порога 0,86. Что свидетельствует об использовании необходимого диапазона допустимых значений во float4, для достижения показателей ошибок близких к полученным в полной точности.

8. Заключение. В рамках статьи проведён анализ изменения ошибок первого и второго рода в задаче распознавания дикторов, при выделении разного количества бит числа с плавающей запятой выходного тензора нейронной сети. Исследованы три SOTA нейросетевых метода CAM++, WavLM и ReDimNet, которые обладают различными архитектурными особенностями. Значения ошибок первого и второго рода базируются на показателях косинусного сходства между эмбеддингами нейронных сетей. На основе полученных значений в таблицах 2-4 построен график, который представлен на рисунке 11.

Метрики распознавания на датасете VoxCeleb-E

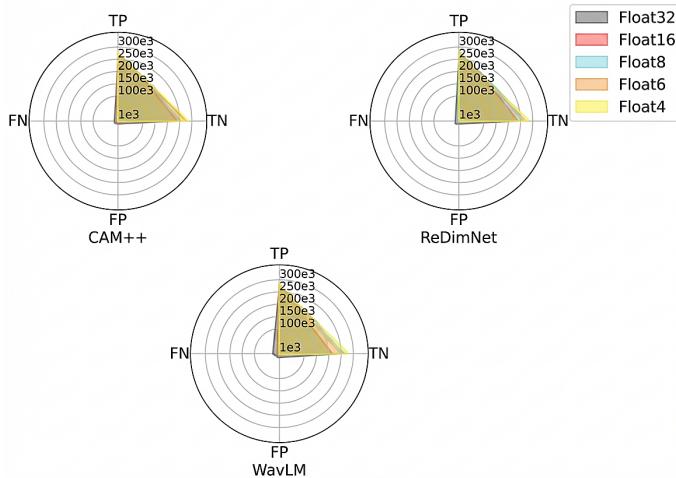


Рис. 11. Значения True Positive, True negative, False Positive и False Negative в зависимости от количества выделенных бит на число

Из данных, представленных на рисунке 11, видно, что при использовании minifloat, площади покрытия метрик, влияющие на показатели ошибок первого и второго рода, практически, совпадают

с результатами, полученными при использовании полной точности. Стоит отметить, что для достижения подобных результатов у WavLM, при выделении четырёх бит на числа эмбеддинга, потребовалось произвести операцию масштабирования на максимальное допустимое значение float4. Результаты, полученные в ходе исследования, показывают, что значения решающего порога, полученные для эмбеддингов в полной точности инвариантны к их квантованию (разница между исходными значениями и квантованными, обычно, не превышает 0,05). Этот факт позволяет сэкономить время при исследовании новых нейросетевых решений. Дальнейшим направлением исследования является разработка нейросетевого метода, устойчивостью к использованию операции квантования к весам, активациям и выходному тензору сети, при этом сохраняя максимально близкие показатели ошибок первого и второго рода, получаемые при работе с полной точностью.

Литература

1. ГОСТ Р 54412-2019 (ISO/IEC TR 24741:2018). Информационные технологии. Биометрия. Общие положение и примеры применения // М.: Госстандарт России. 2019.
2. Morin F., Bengio Y. Hierarchical Probabilistic Neural Network Language Model // Proceedings of the Tenth International Workshop on Artificial Intelligence and Statistics. 2005. pp. 246–252.
3. IEEE Standard for Floating-Point Arithmetic. IEEE Std 754TM-2019 (Revision of IEEE Std 754-2008). 2019. DOI: 10.1109/IEEEESTD.2019.8766229.
4. Google Cloud Blog. BFloat16: The secret to high performance on Cloud TPUs // URL: <https://cloud.google.com/blog/products/ai-machine-learning/bfloat16-the-secret-to-high-performance-on-cloud-tpus> (дата обращения: 28.06.2025).
5. NVIDIA TF32 – DeepRec latest documentation. URL: <https://deepprec.readthedocs.io/en/latest/NVIDIA-TF32.html> (дата обращения: 01.06.2025).
6. Rouhani B.D., et al. OCP Microscaling Formats (MX) Specification. Open Compute Project. 2023.
7. Liu B., Wang H., Qian Y. Towards Lightweight Speaker Verification via Adaptive Neural Network Quantization // IEEE/ACM Trans. Audio Speech Lang. Process. 2024. vol. 32. pp. 3771–3784.
8. Hong Y., Chung W.-J., Kang H.-G. Optimization of DNN-based speaker verification model through efficient quantization technique. arXiv preprint arXiv:2407.08991. 2024.
9. Wang H., Liu B., Wu Y., Chen Z., Qian Y. Lowbit Neural Network Quantization for Speaker Verification // IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW). Rhodes Island, Greece: IEEE, 2023. pp. 1–5.
10. Jouppi N.P., et al. In-Datacenter Performance Analysis of a Tensor Processing Unit // Proceedings of the 44th Annual International Symposium on Computer Architecture. New York, NY, USA: Association for Computing Machinery, 2017. pp. 1–12. DOI: 10.1145/3079856.3080246.

11. Micikevicius P., et al. FP8 Formats for Deep Learning. arXiv preprint arXiv:2209.05433. 2022.
12. Nagrani A., Chung J.S., Zisserman A. VoxCeleb: a large-scale speaker identification dataset // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2017. pp. 2616–2620. DOI: 10.21437/Interspeech.2017-950.
13. Wang H., Zheng S., Chen Y., Cheng L., Chen Q. CAM++: A Fast and Efficient Network for Speaker Verification Using Context-Aware Masking // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2023. pp. 5301–5305. DOI: 10.21437/Interspeech.2023-1513.
14. Колмаков Н.П., Толстых А.А. Устойчивые признаки для распознавания дикторов на дискретных аудиосигналах. Сборник трудов XXIX Международной научно-технической конференции «Радиолокация, Навигация, Связь». 2023. С. 387–394.
15. Chung J.S., Nagrani A., Zisserman A. VoxCeleb2: Deep Speaker Recognition // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2018. pp. 1086–1090. DOI: 10.21437/Interspeech.2018-1929.
16. Huang G., Liu Z., van der Maaten L., Weinberger K.Q. Densely Connected Convolutional Networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. С. 2261–2269. DOI: 10.1109/CVPR.2017.243.
17. Yu Y.-Q., Zheng S., Suo H., Lei Y., Li W.-J. Cam: Context-Aware Masking for Robust Speaker Verification // IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Toronto, ON, Canada: IEEE, 2021. pp. 6703–6707. DOI: 10.1109/ICASSP39728.2021.9414704.
18. Yakovlev I., et al. Reshape Dimensions Network for Speaker Recognition // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2024. pp. 3235–3239.
19. Lin Y., Cheng M., Zhang F., Gao Y., Zhang S., Li M. VoxBlink2: A 100K+ Speaker Recognition Corpus and the Open-Set Speaker-Identification Benchmark // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2024. pp. 4263–4267.
20. Chen S., et al. WavLM: Large-Scale Self-Supervised Pre-Training for Full Stack Speech Processing // IEEE J. Sel. Top. Signal Process. 2022. vol. 16. № 6. pp. 1505–1518.
21. Vaswani A., et al. Attention Is All You Need // Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017. pp. 6000–6010.
22. Hendrycks D., Gimpel K. Gaussian Error Linear Units (GELUs). arXiv preprint arXiv:1606.08415. 2023.
23. GitHub. facebookresearch/libri-light: dataset for lightly supervised training using the librivox audio book recordings. <https://librivox.org/> // URL: <https://github.com/facebookresearch/libri-light> (дата обращения: 02.02.2025).
24. Chen G., et al. GigaSpeech: An Evolving, Multi-Domain ASR Corpus with 10,000 Hours of Transcribed Audio // Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2021. pp. 3670–3674. DOI: 10.21437/Interspeech.2021-1965.
25. Wang C., et al. VoxPopuli: A Large-Scale Multilingual Speech Corpus for Representation Learning, Semi-Supervised Learning and Interpretation // Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021. pp. 993–1003. DOI: 10.18653/v1/2021.acl-long.80.

26. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift // Proceedings of the 32nd International Conference on International Conference on Machine Learning (PMLR). 2015. vol. 37. pp. 448–456.

Колмаков Никита Павлович — младший научный сотрудник, Института проблем передачи информации им. А.А. Харкевича Российской академии наук. Область научных интересов: цифровая обработка сигналов, машинное обучение. Число научных публикаций — 6. kolmakov.np@iitp.ru; Большой Калетный переулок, 19/1, 127051, Москва, Россия; р.т.: +7(495)650-4225.

Голубинский Андрей Николаевич — д-р техн. наук, доцент, Российский научный фонд. Область научных интересов: машинное обучение, нейросетевое моделирование, автоматизированные системы управления с элементами искусственного интеллекта, обработка речевых сигналов. Число научных публикаций — 250. annikgol@mail.ru; улица Солянка, 19-1, 109028, Москва, Россия; р.т.: +7(495)650-4225.

N. KOLMAKOV, A. GOLUBINSKIY

ASSESSING THE INFLUENCE OF FLOATING-POINTS BIT DEPTH ON SPEAKER RECOGNITION ACCURACY*Kolmakov N., Golubinsky A. Assessing the Influence of Floating-Points Bit Depth on Speaker Recognition Accuracy.*

Abstract. The article analyzes the impact of varying the bit depth (quantization) of a neural network's output tensor on speaker recognition accuracy. This tensor represents the neural network's latent space, containing the latent features utilized for speaker recognition tasks. Typically, thirty-two bits are allocated per value in the output space (the output tensors of the methods under study contain 512 values), resulting in significant memory requirements for maintaining a continuously updated database. Consequently, the "minifloat" floating-point format is of particular interest, as it enables numerical representations using only eight, six, or four bits. To ensure comprehensive results, three neural network models demonstrating superior recognition performance on the test set were selected: CAM++, WavLM, and ReDimNet. These models possess unique architectural characteristics, facilitating the assessment of how bit depth reduction affects recognition accuracy across different neural network architectures. Recognition accuracy is evaluated using the Equal Error Rate (EER). The evaluation employs the English-language VoxCeleb-1 dataset, the audio characteristics of which correspond to those of a small-scale biometric system database. The relevance of this study is underscored by the increasing volume of research proposing the use of voice as a verification key. Therefore, managing large biometric datasets requires substantial storage capacity and RAM. Modern databases are continuously updated and expanded, leading to increased resource demands for their maintenance. Applying quantization to the neural network's output tensor offers a potential solution. However, excessive reduction of the bit depth in the output tensor can lead to a significant degradation in recognition quality compared to the baseline network. The primary focus of this research is to minimize the resources required to support a biometric system without the need for additional neural network training.

Keywords: neural networks, speaker recognition, floating point, embedding quantization.**References**

1. GOST R 54412-2019 (ISO/IEC TR 24741:2018). [Information Technology. Biometrics. General Position and Examples of Application] M.: Gosstandart Rossii. 2019. (In Russ.).
2. Morin F., Bengio Y. Hierarchical Probabilistic Neural Network Language Model. Proceedings of the Tenth International Workshop on Artificial Intelligence and Statistics. 2005. pp. 246–252.
3. IEEE Standard for Floating-Point Arithmetic. IEEE Std 754TM-2019 (Revision of IEEE Std 754-2008). 2019. DOI: 10.1109/IEEEESTD.2019.8766229.
4. Google Cloud Blog. BFloat16: The secret to high performance on Cloud TPUs. Available at: <https://cloud.google.com/blog/products/ai-machine-learning/bfloat16-the-secret-to-high-performance-on-cloud-tpus> (accessed 28.06.2025).
5. NVIDIA TF32 – DeepRec latest documentation. Available at: <https://deepprec.readthedocs.io/en/latest/NVIDIA-TF32.html> (accessed 01.06.2025).
6. Rouhani B.D., et al. OCP Microscaling Formats (MX) Specification. Open Compute Project. 2023.

7. Liu B., Wang H., Qian Y. Towards Lightweight Speaker Verification via Adaptive Neural Network Quantization. *IEEE/ACM Trans. Audio Speech Lang. Process.* 2024. vol. 32. pp. 3771–3784.
8. Hong Y., Chung W.-J., Kang H.-G. Optimization of DNN-based speaker verification model through efficient quantization technique. *arXiv preprint arXiv:2407.08991*. 2024.
9. Wang H., Liu B., Wu Y., Chen Z., Qian Y. Lowbit Neural Network Quantization for Speaker Verification. *IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW)*. Rhodes Island, Greece: IEEE, 2023. pp. 1–5.
10. Jouppi N.P., et al. In-Datacenter Performance Analysis of a Tensor Processing Unit. *Proceedings of the 44th Annual International Symposium on Computer Architecture*. New York, NY, USA: Association for Computing Machinery, 2017. pp. 1–12. DOI: 10.1145/3079856.3080246.
11. Micikevicius P., et al. FP8 Formats for Deep Learning. *arXiv preprint arXiv:2209.05433*. 2022.
12. Nagrani A., Chung J.S., Zisserman A. VoxCeleb: a large-scale speaker identification dataset. *Proceedings of the Annual Conference of the International Speech Communication Association Interspeech*. 2017. pp. 2616–2620. DOI: 10.21437/Interspeech.2017-950.
13. Wang H., Zheng S., Chen Y., Cheng L., Chen Q. CAM++: A Fast and Efficient Network for Speaker Verification Using Context-Aware Masking. *Proceedings of the Annual Conference of the International Speech Communication Association Interspeech*. 2023. pp. 5301–5305. DOI: 10.21437/Interspeech.2023-1513.
14. Колмаков Н.П., Толстых А.А. [Robust Speaker Features Recognition on Discrete Audio Signals]. *Sbornik trudov XXIX Mezhdunarodnoj nauchno-tehnicheskoy konferencii «Radiolokacija, Navigacija, Svjaz»* [Proceedings of the XXIX International Scientific and Technical Conference «Radiolocation, Navigation, Communication»]. 2023. pp. 387–394. (In Russ.).
15. Chung J.S., Nagrani A., Zisserman A. VoxCeleb2: Deep Speaker Recognition. *Proceedings of the Annual Conference of the International Speech Communication Association Interspeech*. 2018. pp. 1086–1090. DOI: 10.21437/Interspeech.2018-1929.
16. Huang G., Liu Z., van der Maaten L., Weinberger K.Q. Densely Connected Convolutional Networks. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017. C. 2261–2269. DOI: 10.1109/CVPR.2017.243.
17. Yu Y.-Q., Zheng S., Suo H., Lei Y., Li W.-J. Cam: Context-Aware Masking for Robust Speaker Verification. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Toronto, ON, Canada: IEEE, 2021. pp. 6703–6707. DOI: 10.1109/ICASSP39728.2021.9414704.
18. Yakovlev I., et al. Reshape Dimensions Network for Speaker Recognition. *Proceedings of the Annual Conference of the International Speech Communication Association Interspeech*. 2024. pp. 3235–3239.
19. Lin Y., Cheng M., Zhang F., Gao Y., Zhang S., Li M. VoxBlink2: A 100K+ Speaker Recognition Corpus and the Open-Set Speaker-Identification Benchmark. *Proceedings of the Annual Conference of the International Speech Communication Association Interspeech*. 2024. pp. 4263–4267.
20. Chen S., et al. WavLM: Large-Scale Self-Supervised Pre-Training for Full Stack Speech Processing. *IEEE J. Sel. Top. Signal Process.* 2022. vol. 16. № 6. pp. 1505–1518.

21. Vaswani A., et al. Attention Is All You Need. Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017. pp. 6000–6010.
22. Hendrycks D., Gimpel K. Gaussian Error Linear Units (GELUs). arXiv preprint arXiv:1606.08415. 2023.
23. GitHub. facebookresearch/libri-light: dataset for lightly supervised training using the librivox audio book recordings. <https://librivox.org/>. Available at: <https://github.com/facebookresearch/libri-light> (accessed 02.02.2025).
24. Chen G., et al. GigaSpeech: An Evolving, Multi-Domain ASR Corpus with 10,000 Hours of Transcribed Audio. Proceedings of the Annual Conference of the International Speech Communication Association Interspeech. 2021. pp. 3670–3674. DOI: 10.21437/Interspeech.2021-1965.
25. Wang C., et al. VoxPopuli: A Large-Scale Multilingual Speech Corpus for Representation Learning, Semi-Supervised Learning and Interpretation. Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021. pp. 993–1003. DOI: 10.18653/v1/2021.acl-long.80.
26. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. Proceedings of the 32nd International Conference on International Conference on Machine Learning (PMLR). 2015. vol. 37. pp. 448–456.

Kolmakov Nikita — Junior researcher, Institute for Information Transmission Problems (Kharkevich Institute) Russian Academy of Sciences. Research interests: digital signal processing, machine learning. The number of publications — 6. kolmakov.np@iitp.ru; 19/1, Bolshoy Karetny Lane, 127051, Moscow, Russia; office phone: +7(495)650-4225.

Golubinskiy Andrey — Ph.D., Dr.Sci., Associate professor, Russian Science Foundation. Research interests: machine learning, neural network modeling, automated control systems with artificial intelligence elements, speech signal processing. The number of publications — 250. annikgol@mail.ru; 19-1, Solyanka St., 109028, Moscow, Russia; office phone: +7(495)650-4225.

В.М. ЧЕРТКОВ, Р.П. БОГУШ, Е.Р. АДАМОВСКИЙ, В.С. РОГУЛЕВ
ИМИТАЦИОННАЯ МОДЕЛЬ КОГНИТИВНОГО РАДИО

Чертов В.М., Богуш Р.П., Адамовский Е.Р., Рогулов В.С. Имитационная модель когнитивного радио.

Аннотация. Растущий дефицит радиочастотного спектра, вызванный взрывным ростом числа беспроводных устройств и объемов передаваемых данных, делает технологии когнитивного радио (CR) критически важными для будущего телекоммуникаций. Данное исследование направлено на решение задачи динамического управления спектром путем разработки имитационной модели когнитивной радиосистемы связи, построенной на архитектуре сети LTE. В отличие от существующих решений, предлагаемая модель обладает модульной структурой, что позволяет гибко интегрировать и оценивать различные алгоритмы прогнозирования занятости частотных ресурсов. Модель реализована в среде MatLab и включает три ключевых модуля: модуль формирования и обработки сигналов LTE, генерирующий карты радиосреды (REM); модуль обучения прогнозирующей нейросетевой модели; и модуль прогнозирования занятости частотных ресурсов. Основное внимание удалено использованию передовой архитектуры нейронной сети Колмогорова-Арнольда (KAN) для прогнозирования незанятых блоков планирования (SB) в кадре LTE. В результате имитационного моделирования, охватившего 10 000 кадров, была продемонстрирована высокая эффективность предложенного подхода. Модель KAN обеспечила точность прогнозирования свободных частотных ресурсов на уровне 92,23% для кадра длительностью 10 мс. Проведенное сравнительное тестирование показало, что архитектура KAN превосходит традиционную сеть LSTM по точности примерно на 10% при одинаковом количестве обучаемых параметров, а также быстрее достигает сходимости в процессе обучения. Практическая значимость работы заключается в предоставлении инструмента для точной оценки занятости спектра и планирования доступа вторичных пользователей, что ведет к значительному повышению спектральной эффективности и надежности перспективных беспроводных сетей.

Ключевые слова: когнитивное радио, имитационная модель, LTE, прогнозирование спектра, нейронная сеть Колмогорова-Арнольда (KAN), карта радиосреды (REM), динамический доступ к спектру.

1. Введение. Развитие беспроводных технологий и рост числа подключенных устройств приводят к дефициту радиочастотного спектра. В результате традиционные методы статического распределения частот становятся неэффективными, что стимулирует развитие когнитивного радио (cognitive radio, CR) – технологии, позволяющей динамически перераспределять спектральные ресурсы за счет адаптации к изменяющимся условиям среды [1].

Выделяют следующие основные задачи, решаемые с помощью CR [2]: анализ радиоэлектронной обстановки, оптимизация управления частотными ресурсами, выявление свободных ресурсов путем разработки и применения соответствующих алгоритмов. Каждая из этих задач соответствует крупному направлению научных

исследований. Однако для существующего многообразия методов управления спектральными ресурсами, формирования знаний о радиоэлектронной обстановке и интеллектуальных алгоритмах поиска свободных ресурсов отсутствует общая имитационная модель, позволяющая использовать различные сценарии взаимодействия всех ее объектов и оценивать эффективность применяемый решений. Общая имитационная модель должна обладать следующими ключевыми аспектами [3]: осуществлять мониторинг (зондирование) радиосреды с накоплением знаний об окружающей среде, обнаруживать каналы передачи данных и оценивать их параметры, предсказывать незанятые частотные ресурсы, осуществлять спектральное интеллектуальное управление частотными ресурсами и обеспечивать их динамическое распределение.

При построении модели когнитивной радиосистемы следует учитывать, что карты радиосреды (radio environment map, REM) играют решающую роль в повышении спектральной эффективности и качества обслуживания беспроводных сетей [4]. В работе описаны современные методы построения REM: методы, основанные на моделях распространения радиосигналов; методы, основанные на данных; гибридные методы. Сделан вывод о том, что наиболее перспективными для использования являются гибридные методы, которые интегрируют модели распространения радиосигналов с искусственными нейронными сетями (ИНС), достигая высокой точности даже при ограниченном количестве получаемых данных измерений.

В [5 – 7] определены основные параметры (размер карты, диапазон частот, вид модуляции, мощность излучения), которые согласуются между собой и являются основными для генерации REM. Также представлены оценки эффективности построенных моделей. В качестве основы для имитационной модели CR выбрана гибридная модель, описанная в [7], которая позволяет формировать REM по итерациям с настраиваемым шагом времени.

Задача обнаруживать каналы передачи данных и оценивать их параметры подразумевает подстройку параметров приемников и передатчиков CR для минимизации помех, которые вторичные пользователи (Secondary Users, SU) могут создавать во время передачи своих данных. Для этого решается задача выбора диапазона вещания, выбор протокола и структура передаваемых данных. В [8, 9] используется диапазон частот беспроводной сети передачи данных 4G LTE, как один из самых эффективных для широкополосного беспроводного доступа. Распознавание кадров LTE осуществляется на

основе вида применяемой модуляции, расположения и длительности сигналов синхронизации в кадре. Следует отметить, что большая часть опубликованной литературы по этой теме предполагает системы, основанные на стратегии модуляции OFDM [3, 5, 7, 8, 10].

Отдельной задачей при разработке систем CR является контроль начала и окончания работы первичного пользователя (Primary User, PU) в рабочем диапазоне частот. Для эффективного решения применяются ИНС с целью оценки прогнозирования состояния занятости спектра [10]. Для реализации данного подхода используют архитектуру долгой краткосрочной памяти (Long Short-Term Memory, LSTM) [11], сеть Колмогорова-Арнольда (Kolmogorov-Arnold Network, KAN) [12], сверточные сети (Convolutional Neural Networks, CNN), например, в виде модели U-Net [13]. Выбор архитектуры зависит от специфики входных данных для выявления незанятых частотных ресурсов. Исследования показывают, что точность предсказания свободных частотных ресурсов с использованием нейронных сетей достигает 90%, что делает их эффективным инструментом в данной области [3].

Также не менее важным направлением в CR является разработка и оптимизация алгоритмов поиска незанятых частотных ресурсов с учетом ограниченных вычислительных возможностей и за довольно короткий промежуток времени до 10 мс.

На основе анализа существующих решений можно сделать вывод о необходимости создания имитационной модели CR на модульной архитектуре, обеспечивающей реализацию основных задач, решаемых данной технологией, исследовать поведение всех объектов и их взаимодействия в различных сценариях поведения.

Результаты исследования могут быть использованы для оптимизации алгоритмов динамического спектрального доступа, алгоритмов поиска и обнаружения незанятых частотных ресурсов, повышения спектральной эффективности и надежности беспроводных сетей следующего поколения.

2. Функциональная схема имитационной модели.

Предлагается модульная имитационная модель системы сотовой связи LTE, которая воспроизводит функционирование и взаимодействие ее ключевых объектов: базовых станций (Base Station, BS) и абонентских (пользовательских) устройств (User Equipment, UE). Модель реализована с рядом принятых допущений: радиосигналы распространяются согласно математической модели с параметрами, принятыми для городской застройки; пользовательские данные, передаваемые по каналам связи, формируются генератором псевдослучайных чисел; объем пользовательских данных занимает

весь доступный частотный ресурс; мощности излучения всех устройств постоянны; излучение осуществляется во всех направлениях; базовые станции работают с одной антенной без учета высоты ее подвеса; метод организации дуплексной связи, при котором передача и прием данных производятся на разных частотах (Frequency Division Duplex, FDD); радиосигналы представлены в виде ресурсных сеток (матрица OFDM-символов, являющаяся результатом Фурье-преобразования структуры, сформированной в частотной области).

Имитационная модель реализована в программной среде MatLab и содержит три модуля:

- модуль формирования и обработки сигналов системы сотовой связи LTE, включающий построение REM;
- модуль обучения прогнозирующей нейросетевой модели;
- модуль прогнозирования занятости частотных ресурсов для последующего встраивания данных SU в ресурсную сетку сигнала LTE с использованием информации о незанятых ресурсах системы связи.

Функциональная схема имитационной модели системы сотовой связи LTE с добавлением CR представлена на рисунке 1.

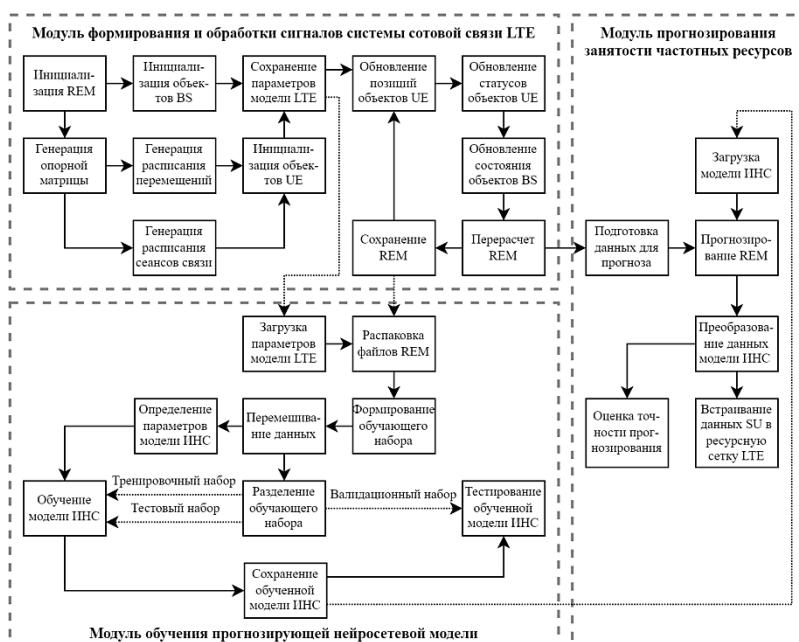


Рис. 1. Функциональная схема имитационной модели когнитивного радио

Первый модуль имитирует работу системы LTE и последовательно формирует выходные данные, содержащие информацию о динамике занятости частотного ресурса в виде карты REM, которая в дальнейшем используется другими модулями.

Задачей модуля обучения прогнозирующей нейросетевой модели является обучение и тестирование ИНС на основе данных карты REM.

Задача последнего модуля состоит в прогнозировании свободных частотных ресурсов с осуществлением оценки точности прогнозирования. При наличии информации о количестве и положении незанятых ресурсов в будущем с помощью технологии когнитивного радио может быть увеличен объем передаваемой информации вторичных пользователей и снижен риск создания помех для РУ.

Отличительной особенностью разработанной имитационной модели CR является использование различных нейросетей и алгоритмов предсказаний незанятых ресурсов с оценкой их точности. Реализация обеспечивается путем использования скриптов на языке программирования Python 3.10, которые непосредственно взаимодействуют с обученными моделями ИНС и возвращают результаты работы через системный интерфейс.

3. Модуль формирования и обработки сигналов системы сотовой связи LTE. Модуль с заданным временным шагом моделирования осуществляет генерацию данных, которые отражают состояние REM в дискретные моменты моделируемого времени на основе обмена данными объектов BS и UE.

Данный модуль состоит из блоков, которые обеспечивают: инициализацию размера и шага REM; инициализацию объектов BS и UE; генерацию расписания сеансов связи UE; генерацию перемещений UE; сохранение параметров модели **сотовой связи** LTE; выполнение основного цикла имитационной модели, в котором производится обновление параметров всех объектов взаимодействия; формирование радиосигналов от всех объектов согласно спецификации LTE [14]; выполнение расчета REM с сохранением результата в отдельный файл.

Рассмотрим основные блоки, входящие в структуру модуля.

1. *Инициализация REM.* Инициализация осуществляется путем считывания константных значений следующих параметров имитационной модели:

- *определение размера и шага карты.* Данные параметры являются настраиваемыми. Значением по умолчанию является размер REM 20×20 ячеек с шагом 250 м. При таких параметрах площадь REM составит $22,5 \text{ км}^2$, что сопоставимо с центральной частью города среднего

размера. Согласно данным карт покрытия 4G LTE [15], расстояние между соседними BS в районах с плотной многоэтажной застройкой составляет 500-800 м, при этом радиус действия базовой станции с несущей частотой 1800 МГц равен 6,8 км на открытой местности [7]. Таким образом, выбранный шаг сетки обеспечивает достаточную точность моделирования перемещения UE.

– *определение временных параметров модели.* Используется частотный диапазон 1800 МГц, который является самым распространенным в сети LTE. Рассматривается только режим радиочастотного доступа FDD. Ширина восходящего канала связи (uplink) и нисходящего канала связи (downlink) настраивается. В модели она составляет 75 МГц, что соответствует 25 ресурсным блокам (Resource Blocks, RB) по 5 МГц. Длина полного кадра LTE в таком случае равна 10 мс. В имитационной модели CR имеется возможность получить любой кадр в рамках заданного временного интервала имитационного моделирования.

2. *Инициализация абонентов и базовых станций.* Этап инициализации объектов UE и BS осуществляется определением их основных параметров и мест расположения на REM. Для инициализации объектов BS используется определенная структура с параметрами: символьное обозначение наименования станции (eNodeBS.name), координаты размещения (eNodeBS.position); идентификационный номер (eNodeBS.NCellID); номер частотного диапазона станции (eNodeBS.freq_band), список устройств, подключенных к данной станции (eNodeBS.UE_RNTI); выделенные и распределенные между UE номера блоков планирования (Scheduling Block, SB) для каждого из канала связи: нисходящего (eNodeBS.UE_DL_RB) и восходящего (eNodeBS.UE_UL_RB).

Наименьшей единицей частотного ресурса для осуществления передачи данных по нисходящей линии является SB, который состоит из двух соседних RB на одинаковых поднесущих. Объем частотного ресурса для осуществления передачи данных по нисходящей линии связи каждой BS представлен на рисунке 2 в виде ресурсной сетки с необходимыми служебными данными [9]: распределение ресурсов (PDCCH), данные для нескольких первичных пользователей (PMCH), формат передаваемых данных (PCFICH), данные обратной связи от первичных пользователей (PHICH), пользовательские (PDSCH), опорных сигналов (RS), первичная синхропоследовательность (PSS), вторичная синхропоследовательность (SSS).

На рисунке 2 зеленым контуром выделен первый и последний подкадры. Синим контуром обозначены соседние RB, которые

в течение одного подкадра объединяются в один блок SB. Нумерация блоков осуществляется снизу вверх и направо, начиная с левого нижнего угла. К примеру, на рисунке 2 указано, что RB№1 и RB№26 образуют SB№1. Следует отметить, что у каждой BS количество SB для нисходящей связи в течение одного кадра (10 мс) составляет $N_{DL} = 250$, что соответствует 25 SB в одном подкадре (1 мс).

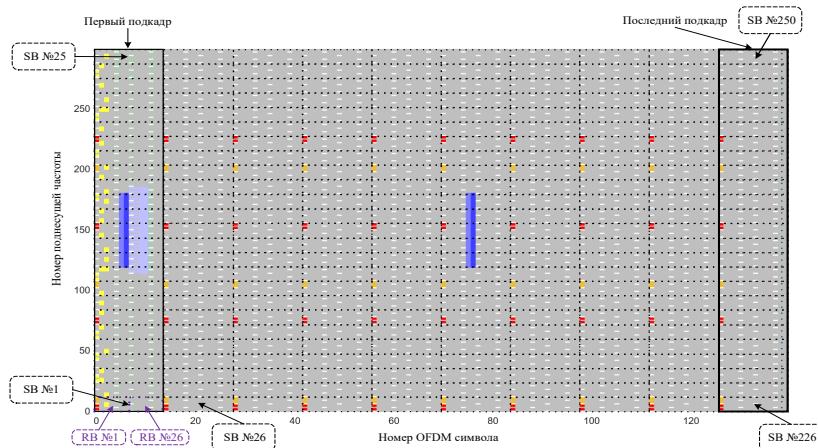


Рис. 2. Объем частотного ресурса базовой станции для осуществления передачи данных по нисходящей линии

В имитационной модели LTE для базовых станций используется жесткое повторное использование полос частот для нисходящих и восходящих каналов связи. При таком подходе происходит разбиение рабочего диапазона частот на три полосы, которые используются различными BS, причем BS с одинаковыми частотными полосами не граничат друг с другом [16]. Расстояние между BS в имитационной модели LTE выбрано равным 1 км, что согласуется расположением BS при средней и низкой плотности застройки.

Количество UE, подключенных к одной BS, зависит от общего объема ее частотного ресурса, который на протяжении всего кадра в имитационной модели составляет 250 SB. Следовательно, к одной BS может подключиться максимум 250 UE с учетом того, что каждому будет выделен только один SB.

Количество объектов UE в имитационной модели LTE является настраиваемым параметром. Стандартный сценарий имитационного моделирования определяет 30 UE и 7 BS.

Объекты UE инициализируются с помощью набора параметров, определяющих его состояние и конфигурацию. К таким параметрам относятся: идентификатор (UE.RNTI), координаты (UE.position), максимальная мощность передатчика (UE.maxPower), статус активности (UE.status), список доступных базовых станций в радиусе действия (UE.base), идентификатор текущей обслуживающей BS (UE.NCellID), назначенный частотный диапазон (UE.freq_band) и выделенные частотные ресурсы восходящего канала (UE.RB). Ключевым параметром является тип устройства (UE.type), который классифицирует UE как PU или SU. Данная классификация определяет, будут ли ему гарантировано выделены ресурсы BS. Для устройств типа SU реализован механизм прогнозирования свободных ресурсов на момент их активации.

На рисунке 3 представлено первоначальное расположение моделируемых объектов BS и UE на REM различных размеров для двух сценариев.

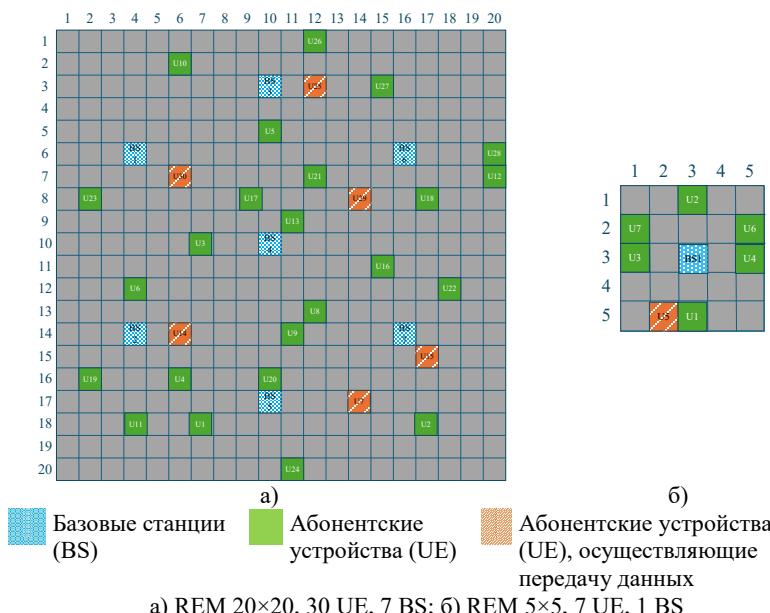


Рис. 3. Расположение объектов абонентов и базовых станций на карте

Первый сценарий предусматривает расположение 7 BS и 30 устройств UE на карте REM с размерами 20×20 ячеек (рисунок 3(а)). Второй моделируемый сценарий содержит одну BS и 7 UE на карте REM размером 5×5 ячеек (рисунок 3(б)). Координаты объектов BS

на REM не изменяются в процессе моделирования. Объекты UE могут перемещаться и находиться в двух состояниях (пассивном и активном), отражающих их поведение в сети связи. В активном состоянии UE осуществляет передачу данных, которая моделируется путем использования всех выделенных ресурсов для этого UE.

Для представленного расположения объектов по сценарию 2 (рисунок 3(б)) в таблице 1, приведен пример конфигурации объектов UE.

Таблица 1. Инициализированные значения основных параметров объектов UE

Наименование, параметр [тип данных]	UE №1	UE №2	UE №3	UE №4	UE №5	UE №6	UE №7
Наименование устройства, name [char]	#1 PU	#2 PU	#3 PU	#4 PU	#5 PU	#1 SU	#2 SU
Координаты расположения, position [int, int]	[5, 3]	[1, 3]	[3, 1]	[3, 5]	[5, 2]	[2, 5]	[2, 1]
Идентификатор BS, NCellID (int)	1	1	1	1	1	0	0
Номер частотного диапазона BS, freq band (int)	1	1	1	1	1	0	0
Идентификационный номер UE, RNTI (int)	1	2	3	4	5	6	7
Ограничение на мощность передачи, maxPower (double)	23.0	23.0	23.0	23.0	23.0	23.0	23.0
Выделенные ресурсы для восходящей линии, RB [int,]	[2, 3, 4, 5]	[6, 7, 8, 9]	[10, 11, 12, 13]	[14, 15, 16, 17]	[18, 19, 20, 21]	[]	[]
Статус активности, Status (bool)	0	0	0	0	1	0	0
Расписание перемещения по карте REM, trajectory (int, int, int)	455×3	455×3	455×3	455×3	455×3	[0, 2, 5]	[0, 2, 1]
Соседние BS в радиусе видимости, base (cell)	0×0 cell	0×0 cell	0×0 cell	0×0 cell	0×0 cell	0×0 cell	0×0 cell
Расписание передачи данных, dataTransfer (int, int)	5887×2	5875×2	5650×2	5889×2	6512×2	5756×2	5751×2
home_time	47	29	113	232	14	230	48
work_time	393	375	459	578	360	576	394
Тип устройства, type (PU или SU)	PU	PU	PU	PU	PU	SU	SU
Ресурсной сетки для связи по восходящему каналу, remSimp (int8)	1872×140	1872×140	1872×140	1872×140	1872×140	1872×140	1872×140

В таблице представлены параметры для каждого UE, с учетом того, что они подключены к BS1 с выделением им частотных ресурсов. В данном примере объекты от UE №1 до UE №5 являются устройствами типа PU, а UE №6 до UE №7 устройствами типа SU.

Дополнительно включен параметр UE.remSimp, который хранит значение сформированной ресурсной сетки для связи по восходящему каналу (uplink) для каждой UE. Этот параметр представляет собой матрицу размером 1872×140 , что соответствует 1872 поднесущим частотам и 140 ODFM символам. При инициализации матрица заполняется нулями. При формировании ресурсной сетки отдельно для каждого UE значения, хранимые в каждой ячейке, определяют уровень сигнала на соответствующей поднесущей. Значения матрицы UE.remSimp пересчитываются каждый раз, когда UE меняет свой статус активности.

3. *Формирование расписания перемещений и сеансов связи UE.* Процесс формирования расписания для абонентов подразумевает создание шаблонной структуры. Данный шаблон задает состав и последовательность управляющих параметров, к которым относятся: временная метка (отсчет в пределах суток), классификация дня (рабочий, выходной или праздничный), день недели, а также неделя в рамках текущего месяца [17]. Полученные шаблоны обладают фиксированной длительностью, которая зависит от шага моделирования, на их основе определяются: время инициализации события и его длительность в течение суток. Генерация шаблонов представлена на листинге 1 и содержит перебор всех возможных комбинаций свойств и присвоения каждой из них уникальной бинарной последовательности, сформированной цепью Маркова.

При инициализации модели формируется календарь на устанавливаемое количество дней, который включает регулярную сетку рабочих и выходных дней с добавлением небольшого количества праздничных дней случайным образом. Затем для каждого объекта UE на основе структуры-шаблона формируется посutoчное расписание перемещений и сеансов связи. Расписание перемещений представляет собой список, содержащий отсчет времени и целевые координаты. Используются две опорные точки на REM: рабочее место и домашнее место, а также оперирует значениями начала и конца рабочего дня. В рабочие дни и рабочее время объекты UE находятся по координатам своих рабочих точек, в остальное время они перемещаются на домашние точки. Расписание сеансов связи включает список времени начала сеанса и его длительность [7].

```
emitions = [0.5 0.5; 0.5 0.5]; % матрица выбросов
result_data = {};
for l = 1:number_UE % инициализация таблицы расписания
    n = 1; % цикл по каждому абоненту
    записей % инициализация счетчика нумерации
    data = table; % инициализация новой записи
    for i = 1:days_in_week % цикл по количеству дней недели
        for j = 1:days_in_type % цикл по количеству типов дней
            for k = 1:week_in_month % цикл по количеству недель в месяце
                data.Combination(n, :) = % запись комбинации нормированных
признаков
                [i / days_in_week j / days_in_type k / week_in_month];
                state_1 = 0.85 + (0.1 * rand()); % вероятность перехода в другое
состояние
                state_2 = 1 - state_1; % вероятность перехода в то же состояние
                transitions = [state_1 state_2 % матрица переходов
                               state_2 state_1];
                [~, state] = % генерация последовательности
                hmmgenerate(samples_in_day, transitions, emitions);
                data.Base(n, :) = state - 1; % запись нормированной
последовательности
                n = n + 1; % увеличение счетчика
            end
        end
    end
    result_data{} = data; % добавление записи в таблицу
end
```

Листинг 1. Генерация шаблонов

В расписание сеансов связи дополнительно налаживается импульсный шум «соль и перец» заданной плотности, который вносит в готовый шаблон уникальную хаотичность. Программный код данной операции представлен на листинге 2. Дополнительно обнуляются начальные и конечные фрагменты шаблонов, что соответствует ночному времени суток, когда объект UE не активен.

Представленный алгоритм осуществляет перебор сформированных шаблонов для каждого объекта UE. При совпадении комбинаций поведения, у одного UE добавляется в шаблон импульсный шум заданной плотности, который имитирует определенный уровень непредсказуемости поведения, характерный для реальных абонентов.

```

for m = 1:number_UE
    prepared = [];
    % цикл по каждому абоненту
    % инициализация массива
    поведения
        for i = 1:years * days_in_year
            % цикл по количеству лет
            for j = 1:height(ref{m})
                % цикл по готовым шаблонам
                if (week(:, i) == ref{m}.Combination(j, :)) % для подходящей комбинации
                    temp = imnoise( % добавление в шаблон импульсного
                    шума
                        ref{m}.Base(j, :), 'salt & pepper', noise_p);
                    temp(1:UE{m}.home_time) = 0; % обнуление данных в утреннее
                    время
                    temp(UE{m}.work_time:samples_in_day) = 0; % обнуление данных в
                    вечернее время
                    prepared = [prepared temp]; % добавление фрагмента
                    поведения
                end
            ...
        end
    ...
end

```

Листинг 2. Генерация с добавлением импульсного шума

4. *Обновление позиций абонентов.* На каждом шаге итерационного процесса модели производится актуализация координат абонентских устройств в соответствии с назначенными траекториями их перемещений. На листинге 3 представлено функция обновления координатных позиций UE.

```

function time_ = MoveUE(time)
    global flag_move;
    global UE;
    kol_ue = size(UE, 2);
    flag = false;
    for num_ue = 1:kol_ue
        k = find(UE{num_ue}.trajectory(:,1) == time); % поиск в расписании
        if (isempty(k) == 0)
            UE{num_ue}.position = UE{num_ue}.trajectory(k, 2:3); % перемещение UE
            flag = true; % установка флага на проверку переподключения
        end
    end
    flag_move = flag_move | (flag); % обновление глобального флага на проверку
    переподключения
end

```

Листинг 3. Функция обновления координатных позиций UE

Алгоритм из листинга 3 осуществляется поиск в расписании каждого абонента временного отсчета, заданного через аргумент

функции. Аргумент, передаваемый в функцию MoveUE(time), хранит временной отсчет моделирования системы. При положительном результате поиска осуществляется перемещение объекта UE в новые координаты. Также устанавливается логический флаг, инициирующий проверку целесообразности подключения к другой BS на основе сравнения уровней мощности сигнала от соседних базовых станций.

Листинг 4 описывает код функции проверки условий переподключения объекта UE к новой базовой станции или отключение от текущей BS с перераспределением частотных ресурсов. Условием переподключения является превышение уровня сигнала от другой BS над уровнем сигнала текущей станции.

```
function time_ = Reconn_simp()
    global UE; % список всех устройств UE
    global eNodeBS; % список всех станций BS
    global flag_gen_rem; % флаг для перегенерации REM
    kol_ue = size(UE, 2); % определение количества UE
    устройств
        for num_ue = 1:kol_ue % перебор по всем устройствам UE
            if (strcmp(UE{num_ue}.type,'PU')) % если устройство имеет тип PU
                out = near_base(num_ue); % оценка условий подключения к каждой
                S
                else
                    out = 0; % переподключение не требуется
                end
                switch out % выбор действия
                    case -1
                        disconnect_ue(num_ue, UE{num_ue}.NCellID); % отключение UE
                        flag_gen_rem = true; % установка флага для генерации REM
                    case 0
                        continue
                    otherwise
                        disconnect_ue(num_ue, UE{num_ue}.NCellID); % отключение UE
                        connect_ue(num_ue, eNodeBS{out}.NCellID); % подключение UE к
                        новой BS
                        flag_gen_rem = true; % установка флага для генерации REM
                end
            end
        end
```

Листинг 4. Функция проверки условий переподключения объекта UE к новой базовой станции или отключение от текущей BS с перераспределением частотных ресурсов

Операция переподключения осуществляется путем вызова функции `disconnect_ue()` и `connect_ue()`, которые отвечают за отключение от старой и подключение к новой станции с распределением всего частотного ресурса соответствующей BS. Распределению подлежат зарезервированные блоки SB для исходящей линии (`eNodeBS.UE_DL_RB`) между всеми подключенными объектами UE. Распределение частотного ресурса осуществляется по алгоритму, описанному в работе [7].

Возможна ситуация, когда происходит только отключение при условии, что значение принимаемого от всех станций сигнала меньше порогового уровня помех. В таких случаях происходит только отключение с последующим распределением частотного ресурса между оставшимися объектами UE, подключенными к конкретной BS, как показано в Листинге 5.

```

function err = disconnect_ue(num_ue, NCellID)
global UE; % список всех устройств UE
global eNodeBS; % список всех станций BS
global KOL_RB;
NDLRB = KOL_RB; % количество ресурсных блоков (ширина
канала)
kol_eb = size(eNodeBS,2); % количество станций BS
num_eb = 0;
kol_all_ue = size(UE,2); % количество устройств UE

% Поиск базовой станции, к которой подключено устройство
for i=1:kol_eb
    if (eNodeBS{i}.NCellID == NCellID) % условие совпадения
        num_eb = i; % запоминаем порядковый номер BS
        break;
    end
end

buf = size(eNodeBS{num_eb}.UE_RNTI); % Список всех устройств
подключенных к BS
xx = buf(2); % Количество подключенных устройств UE
num_eb_ue = 0;
RNTI = UE{num_ue}.RNTI; % Идентификатор отлучаемого устройства

% Поиск номера устройства среди всех подключенных устройств UE к
найденной BS для ее последующего отключения
for i=1:xx
    if (eNodeBS{num_eb}.UE_RNTI(i) == RNTI)
        num_eb_ue = i;
    end
end

```

```
break;
end
end

% Обнуление выделенного ресурса
eNodeBS{num_eb}.UE_RNTI(num_eb_ue) = [];

% Распределение SB между UE по нисходящей линии связи.
buf = size(eNodeBS{num_eb}.UE_RNTI);           % количество подключенных
устройств UE
kol_ue = buf(2);

if (kol_ue == 0)
    k1 = 0;
    p1 = 0;
else
    % высчитываем по равному количеству SB на каждое UE устройство
    k1 = fix((NDLRB*10)-2)/kol_ue;
    p1 = 1:k1*kol_ue;           % номера всех ресурсов подлежащих распределению
    p1 = p1 + 1;
end

% Распределение SB между UE по k1 блоков.
u=1;
p3 = [];
for i=1:kol_ue
    p3(i,1) = eNodeBS{num_eb}.UE_RNTI(i);
    for j=1:k1
        p1(2,u) = eNodeBS{num_eb}.UE_RNTI(i);
        p3(i,j+1) = p1(1,u);
        u=u+1;
    end
end

eNodeBS{num_eb}.UE_DL_RB = p3;    % запись итогового распределения
ресурсов

% Обнуление информации о подключении к BS для обрабатываемого UE
UE{num_ue}.NCellID = 0;
UE{num_ue}.freq_band = 0;
UE{num_ue}.maxPower = 0;
UE{num_ue}.RB = [];
err = 0;
end
```

Листинг 5. Функция отключения UE от BS

Алгоритм работы функции отключения `disconnect_ue()` осуществляет поиск станции, к которой было подключено рассматриваемое устройство с получением информации о распределении ресурсов между всеми подключенными к ней объектами UE. Далее проверяется соответствие порядного номера отключаемого абонента с номером RNTI, который используется для распределения ресурсов. На следующем этапе осуществляется обнуление распределенных ресурсов и определение количества блоков SB для оставшихся устройств. Распределение осуществляется, последовательно закрепляя за каждым объектом UE равное количество блоков SB, фиксируя для каждого из них идентификатор RNTI устройства, которое занимает этот блок. Окончательным этапом производится обнуление информации в структуре отключаемого UE о базовой станции, к которой осуществлялось подключение.

Рассмотрим пример из рисунка 3(б) и таблицы 1. Представим, что устройство UE (U2) вышло из радиуса видимости BS. Тогда данное устройство будет отключено с перераспределением частотного ресурса базовой станции. На рисунке 4 представлено распределение ресурсов до отключения UE (U2), а на рисунке 5 после отключения с перераспределением.

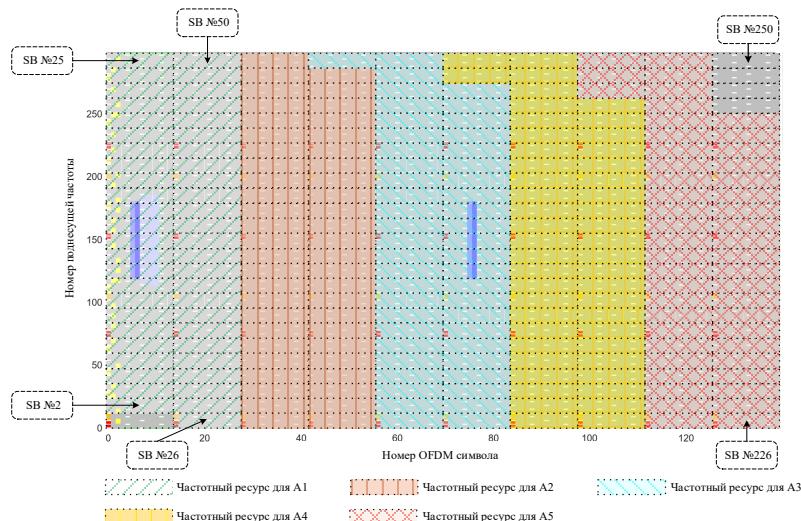


Рис. 4. Распределение ресурсов BS до отключения UE (U2)

Из рисунка 4 видно, что каждому подключенному UE к BS выделено равное количество блоков SB, а именно 49 единиц. Так,

например, для UE(U1) выделены блоки SB под номерами от 2 до 50. Для более наглядного представления выделение SB для каждого UE осуществлялось последовательно группами соседних блоков.

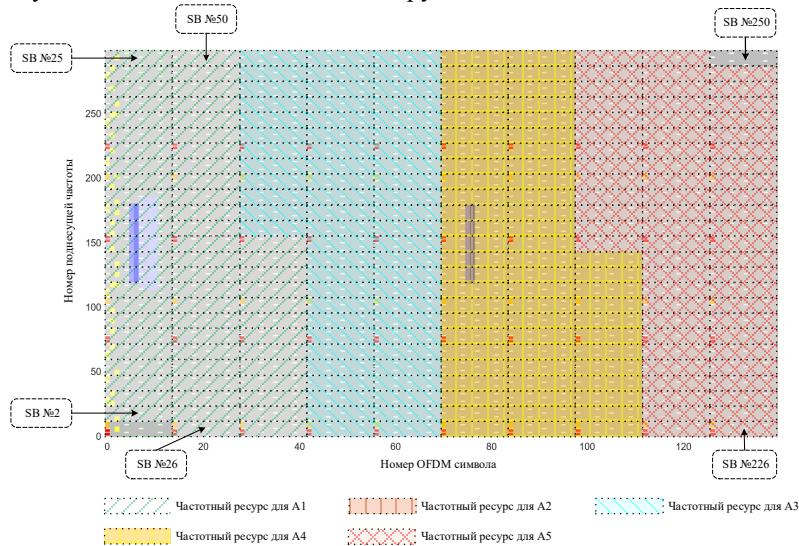


Рис. 5. Распределение ресурсов BS после отключения UE (A2)

Из рисунка 5 видно, что количество выделенных блоков SB для каждого объекта UE увеличился до 62, а для UE (U2) ресурсов выделено не было.

5. *Обновление статусов абонентов.* Изменение статусов активности абонентских устройств для передачи данных в соответствии с их индивидуальным расписанием. В модели реализован перебор объектов UE с поиском записи в расписании о начале сеанса в данный момент времени. При обнаружении подходящей записи соответствующий объект UE изменяет состояние на активное. На следующей итерации устройство связывается со своей рабочей станцией и начинает передачу данных. Для передачи используются все выделенные данному устройству блоки SB. Если объект UE не активен, то для связи по каналам вверх и вниз используется только по одному блоку SB из списка выделенных, которые имитируют различные сервисные данные.

Если время сеанса связи превысило длительность, указанную в расписании, абонент завершает передачу данных и переходит в неактивное состояние. На любое изменение изменения статуса

передачи устанавливается логический флаг в истинное значение, отвечающий за запрос на перерасчет REM.

6. *Обновления состояний объектов BS.* С целью формирования имитационного радиосигнала от BS согласно спецификации LTE, в MatLab применяется функция `lteRMCDLTool()` с параметрами, которая запускает приложение «LTE Waveform Generator» с заданной конфигурацией. Параметрами функции выступают: конфигурация BS в виде структуры данных и вектор информационных битов для реализации псевдослучайного распределения частотных ресурсов в генерируемом кадре.

Начальной конфигурацией для всех объектов BS является эталонная модель канала R.6 [14], которая дополняется параметрами в зависимости от временного шага моделирования, подключенных объектов UE к ней, а также статуса активности последних. Статус активности показывает, осуществляется ли передача данных в текущий момент моделируемого времени.

Информационные биты, представляющие полезную нагрузку, передаются в виде массива ячеек, содержащего один или два вектора битовых значений. В дальнейшем они циклически заполняют весь выделенный объем частотного ресурса. Пример формирования имитационного радиосигнала BS описан в листинге 6.

```

rmc = lteRMCDL('R.6');           % используемая эталонная модель
% задание статических параметров
rmc.TotSubframes = 10;           % количество моделируемых
подкадров
rmc.NSubframe = 0;                % начальный подкадр
моделирования
rmc.CellRefP = 1;                  % количество антенн
rmc.OCNGPDSCH.Modulation = '16QAM'; % тип применимой модуляции
rmc.NDLRB = NDLRB;                % ширина полосы, количество RB (25)
% динамические параметры
rmc.NCellID = NCellID;            % идентификатор сотовой
rmc.PDSCH.RNTI = RNTI;            % номер кадра для которого
rmc.NFrame = NFrame;               % осуществляется генерация данных
rmc.PDSCH.PRBSets = RB_DL;        % набор ресурсов для распределения между
подключёнными UE
% формирование радиосигнала и ресурсной сетки станции BS
[signal, txGrid, rmc_out] = lteRMCDLTool(rmc, [1; 0; 0; 1]);

```

Листинг 6. Формирование имитационного радиосигнала BS

Помимо эталонных значений по умолчанию, для каждой станции прописываются собственные параметры, которые были заданы при инициализации в отдельности и имеют отличные от эталонных значения. Такие параметры разделяются на статические и динамические. Первые едины для всех объектов BS, а вторые зависят от конкретной BS, и процесс ее работы меняют свои значения. Следует отметить, что генерируется как радиосигнал, так и ресурсная сетка, которую можно восстановить по этому радиосигналу.

На рисунке 6 представлен результат работы приложения Wireless Waveform Generator в MatLab, использовавший функцию `lteRMCDLTool()`, в виде сформированной ресурсной сетки для эталонного канала R.6 с заполненными статическими параметрами. Данное приложение используется для наглядного представления передаваемых данных по нисходящему каналу в зависимости от заполняемых статических параметров BS. Генерируются все служебные и пользовательские данные, которые выделены различным цветом на рисунке 6.

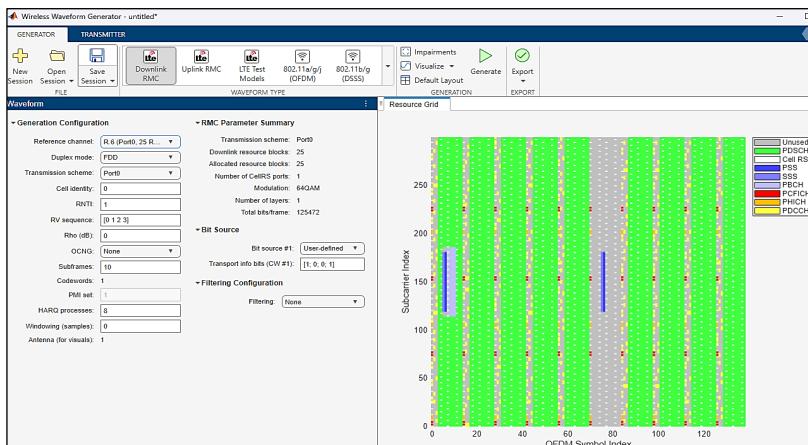


Рис. 6. Ресурсная сетка эталонного канала R.6

В приведенном на рисунке 6 случае, для передачи данных используются все блоки SB, за исключением подкадра №5, где в эталонной модели R.6 предусмотрена передача блоков данных системной информации (System Information Blocks, SIB). Представленная ресурсная сетка содержит все служебные и пользовательские данные, которые передаются объектам UE [9]. Поскольку используется ширина в 25 RB, то на рисунке 6 мы видим

300 поднесущих ($25*12 = 300$), где каждый RB занимает 12 поднесущих. Длительность соответствует 140 OFDM символа, что равно одному кадру LTE длительностью 10 мс.

На рисунке 7 представлена ресурсная сетка BS с заполненными статическими и динамическими параметрами эталонной модели R.6 согласно листингу 4. Ресурсная сетка BS использует для передачи некоторые блоки SB, часть из которых пронумерована. Данные блоки содержат информацию, которая предназначена для подключенных к этой станции абонентов. Если устройство не активно, то заполняется данными только один из выделенных блоков SB.

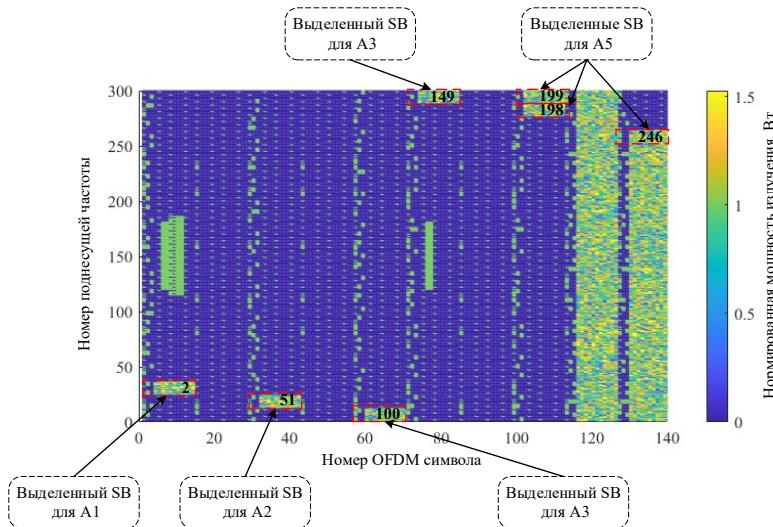


Рис. 7. Ресурсная сетка BS с заданными дополненными параметрами

Рисунок 7 описывает ресурсную сетку BS в момент времени, в который активно только одно UE (U5) и соответствует рисунку 3(б). Для него передаются данные от базовой станции, причем задействуются все выделенные RB для UE(U5). Блок SB, в котором осуществляется передача данных, содержит ресурсные элементы (RE), имитируют информационные биты, уровень мощности которых выше 0. Для рассматриваемого случая из рисунка 7 представлена таблица 2, которая содержит информацию о распределении ресурсных блоков BS для подключенных к ней объектов UE.

Поскольку активно только одно устройство U5, то информационными битами будут заполнены все ему выделенные блоки

SB (от SB198 до SB246). Также окажутся заполненными информацией SB под номерами SB2, SB51, SB100, SB149 потому как они являются первыми выделенными блоками и подлежат обязательному заполнению.

Таблица 2. Выделенные ресурсные блоки для каждого подключенного UE устройства к BS

Номер UE устройства	Номера SB выделенных UE для осуществления передачи данных по нисходящей линии	Статус активности
A1	2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 50	0
A2	51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92, 93, 94, 95, 96, 97, 98, 99	0
A3	100, 101, 102, 103, 104, 105, 106, 107, 108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122, 123, 124, 125, 126, 127, 128, 129, 130, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 141, 142, 143, 144, 145, 146, 147, 148	0
A4	149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180, 181, 182, 183, 184, 185, 186, 187, 188, 189, 190, 191, 192, 193, 194, 195, 196, 197	0
A5	198, 199, 200, 201, 202, 203, 204, 205, 206, 207, 208, 209, 210, 211, 212, 213, 214, 215, 216, 217, 218, 219, 220, 221, 222, 223, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 234, 235, 236, 237, 238, 239, 240, 241, 242, 243, 244, 245, 246	1

7. *Пересчет карты радиосреды.* Пересчет REM запускается при изменении координат объектов UE либо после смены статуса их активности.

На первом этапе производится обновление ресурсных сеток каждой станции путем параллельного перебора всех объектов BS с обновлением их ресурсных сеток с помощью функции `lteRMCDLTool()`. После обновления ресурсные сетки размещаются в соответствии с координатами расположения станций. Перед размещением обновленная ресурсная сетка помещается в рабочий частотный диапазон текущей базовой станции.

Для каждого объекта UE также осуществляется параллельный перебор с обновлением ресурсных сеток с помощью функции `lteRMCLTool()`, отвечающую за генерацию сигнала и ресурсной сетки по восходящему каналу связи. На каждую сформированную сетку накладывается шумовое воздействие с заданным коэффициентом

воздействия, измеряемым в дБ. После завершения процедуры обновления ресурсных сеток и их размещения на карте REM выполняется этап объединения сеток в каждой ячейке REM.

На второй этапе распространение излучающего сигнала (ресурсной сетки) вычисляется отдельно для каждого объекта по упрощенной модели его затухания, которая описывает три уровня сигнала при его распространении: «нормальный», «слабый» и «потеря сигнала». Каждый уровень устанавливается в зависимости от расстояния от точки излучения на карте REM, поэтому высчитываются и суммируются все промежуточные REM от каждого объекта модели. Таким образом, в каждой ячейки карты REM хранятся объединенные значения ресурсных сеток по частотным диапазонам.

На рисунке 8 представлен пример этапа размещения ресурсных сеток от всех объектов на REM. Данный этап подразумевает перебор всех объектов и заполнение ячеек REM сигналами передачи данных (ресурсными сетками) в местах их расположения с учетом занимаемых выделенных частотных диапазонов.

В примере на рисунке 8 в ячейке (3, 3), где расположена базовая станция B1, ее ресурсная сетка располагается в первом частотном диапазоне, который занимает от 900 до 1200 поднесущих. Следует отметить, что весь моделируемый диапазон поднесущих частот разбит на 6 частотных полос, по 3 частотных диапазона на нисходящий и восходящий каналы:

- первый частотный диапазон занимает для нисходящий от 900 до 1200 поднесущих, а для восходящей от 0 до 300;
- второй частотный диапазон занимает для нисходящий от 1200 до 1500 поднесущих, а для восходящей от 300 до 600;
- третий частотный диапазон занимает для нисходящий от 1500 до 1800 поднесущих, а для восходящей от 600 до 900.

Ресурсная сетка от активного объекта UE (U5) в ячейке REM (5,2) по восходящей линии связи занимает весь выделенный ей ресурс и располагается в первом частотном диапазоне для восходящей линии связи. Так как пример на рисунке 8 содержит только один объект BS (B1), то все сигналы будут располагаться в первом частотном диапазоне. Разные частотные диапазоны, как правило, используются соседними станциями. Остальные объекты UE (U1, U2, U3, U4), каждый в своей ячейке, занимают по одной выделенной линии, которая была назначена при распределении частотных ресурсов во время подключения к BS, для осуществления связи по восходящему каналу в первом частотном диапазоне.

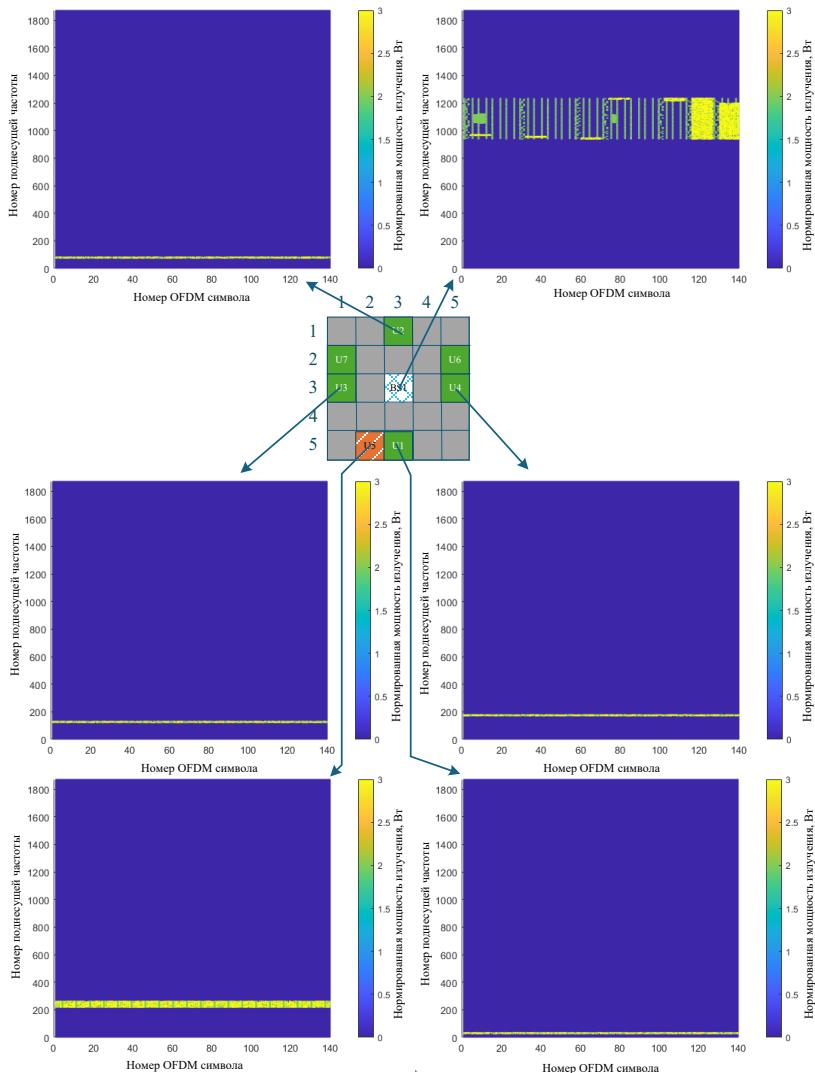


Рис. 8. Размещение ресурсных сеток на REM

На рисунке 8 стрелки указывают на ресурсные сетки (радиосигналы), которые хранятся в ячейке, где располагается соответствующий объект на REM. Отметим, что объекты U6 и U7 не излучают сигналов, т.к. являются устройствами типа SU, т.е. они

не подключаются к базовым станциям. Следовательно, для них не выделяются ресурсы.

На рисунке 9 представлен результат объединения ресурсных сеток всех объектов на REM в ячейке (3,3), где расположена станция B1, с учетом затуханий от мест расположения каждого объекта до представленной ячейки. Объединение (суммирование) всех ресурсных сеток от каждого объекта на REM осуществляется для всех ячеек.

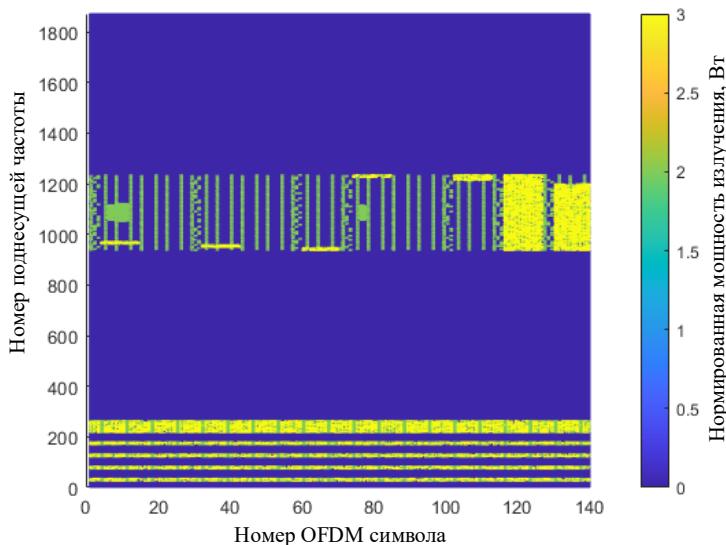


Рис. 9. Объединенный частотный диапазон в точке расположения базовой станции (B1)

8. *Сохранение карты радиосреды в файл.* Сохранение данных REM на внешний носитель информации. В качестве способа представления используется формат HDF5 по ряду причин: наличие в MatLab инструментов для работы с этим форматом, высокая скорость записи и чтения данных, универсальность формата. Таким образом, выходными данными моделями является набор HDF5 файлов с расширением «.h5», каждый из которых содержит полную карту радиосреды в заданный момент моделируемого времени. С целью экономии памяти дополнительно производится архивация полученного файла в формат «zip», что позволяет уменьшить размер до 50 раз за счет разреженности матрицы REM. Отдельно сохраняются

параметры модели для возможности генерации обучающих данных по сохраненным снимкам REM.

4. Модуль обучения прогнозирующей нейросетевой модели.

Модуль построен на нейронной сети KAN, которая демонстрирует превосходную точность по сравнению с другими ИНС при аналогичном числе параметров для задачи прогнозирования незанятых частотных ресурсов в системе сотовой связи LTE [12].

Рассматриваемый модуль состоит из следующих основных блоков (рисунок 1): загрузка параметров модели LTE, распаковка сжатой карты REM, формирование набора для обучения ИНС, перемешивание данных, разделение обучающегося набора на тренировочную, тестовую и валидационную часть, определение параметров модули ИНС, обучение модули ИНС, тестирование обученной модели ИНС, сохранение обученной модели ИНС.

Рассмотрим основные блоки модуля.

1. Загрузка параметров модели осуществляется путем чтения файла конфигурации параметров модели LTE (файлов расписания перемещений и сеансов связи пользователей, первоначальная расстановка всех объектов BS и UE, и их параметры).

2. Загрузка и распаковка файлов REM в предварительную структуру данных, которая позволяет рассчитать статусы занятости слотов в анализируемом кадре LTE.

3. Формирование обучающего набора включает расчет статусов занятости блоков SB для каждой линии RB. Блок SB считается занятым, если его уровень превышает общий уровень шума на заданное значение.

Ключевым этапом в генерации обучающего набора данных является формирование соответствия между входной и выходной информацией модуля обучения прогнозирующей ИНС, которая отражена в таблице 3.

Таблица 3. Структура данных для обучения прогнозирующей модели

Входные данные					Выходные данные
Номер отсчета в сутках	Номер дня недели	Тип дня	Номер недели месяца	Номер линии RB	Статус 10 блоков SB кадра LTE

Таким образом, входные данные поступают от модуля формирования и обработки сигналов системы сотовой связи LTE. Выходные данные содержат статус 10 блоков SB в каждом анализируемом кадре LTE для выбранной линии RB (рисунок 2).

Следует отметить, что прогнозирование осуществляется для отдельной линии RB, а не для всей ресурсной сетки в целом.

4. Блок комбинирования и разделения подготовленных данных на отдельные выборки: обучающую (60%), тестовую (20%) и валидационную (20%).

5. Блок инициализации модели ИНС, загрузка данных, обучение и тестирование.

6. Сохранение в файл весов обученной модели ИНС для последующего использования модулем прогнозирования занятости частотных ресурсов. Веса модели КАН после обучения сохраняются в бинарный файл и в дальнейшем могут быть использованы для выполнения прогнозирования с помощью специального скрипта на языке Python.

5. Модуль прогнозирования занятости частотных ресурсов.

Модуль выполняет прогнозирование занятости частотных ресурсов в виде содержимого заданной ячейки REM имитационной модели LTE, и включает основные блоки: загрузка обученной модели ИНС, подготовка исходных данных текущей REM для подачи на вход ИНС, процедура прогнозирования, оценка точности прогнозирования.

Модуль прогнозирования занятости частотных ресурсов был реализован в виде скрипта на языке Python 3.11. Функционал данного скрипта включает загрузку весовых коэффициентов предварительно обученной искусственной нейронной сети (ИНС) и значения, соответствующие входным данным (таблица 3). Скрипт возвращает результаты прогнозирования в текстовом виде. Вызов скрипта осуществляется путем системного вызова с набором параметров, как показано в листинге 7.

```
function predict = PredictKAN(inp) % объявление функции
    [~, ans] = system(inp); % системный вызов Py-скрипта
    ans(1) = ""; ans(length(ans)) = ""; % удаление лишних символов
    ans(length(ans)) = ""; ans = strsplit(ans, ' '); % разделение строки на 10
    символов
    predict = ones(1, 10); % инициализация результирующего
    массива
    for i = 1 : 10 % цикл по каждому элементу
        predict(i) = str2num(ans{i}); % преобразование каждого символа в
        число
    end % завершение цикла и возврат в
    основную программу результата
end
```

Листинг 7. Системный вызов Python скрипта

Полученный результат преобразуется в массив логических значений, производится сравнение прогноза и текущего состояния модели.

6. Результаты имитационного моделирования.

Имитационной моделью были сформированы данные в виде файлов, содержащих матрицы REM. Набор смоделированных данных для обучения и тестирования нейросетевой модели составил 10 000 кадров LTE за 12 месяцев моделируемого периода: 6 000 кадров для обучения и по 2 000 кадров для тестирования и валидации. Для оценки результата предсказаний также было смоделировано 10 000 кадров LTE, но уже с другими параметрами при инициализации всех объектов карты REM. Размеры карты REM были установлены 5×5 ячеек, 7 объектов UE, одна базовая станция.

Точность прогнозирования занятости частотных ресурсов измерялась путем подсчета отношения корректно предсказанных отсчетов ко всем анализируемым отсчетам согласно выражению:

$$P = 100\% \cdot \left(1 - \frac{Y}{S} \right), \quad (1)$$

где P – точность прогноза;

Y – количество корректно подсчитанных предсказаний;

S – общее количество предсказаний.

Модель ИНС возвращает предсказания в виде вероятности занятости частотного ресурса в диапазоне от 0 до 1, где 0 – не занят, 1 – занят. Для приведения прогноза модели к логическому типу данных вводился коэффициент бинаризации, представляющий пороговое значение ($th = 0,5$) относительно которого определялось состояние занятости ресурса.

На рисунке 10 представлен результат оценки точности прогнозирования свободных частотных ресурсов.

Оценка выполнялась по каждому кадру с вычислением среднего значения предсказаний для всего кадра LTE. На рис. 10 представлены результаты для 100 усредненных кадров, что соответствует 10000 сгенерированных кадров LTE. Штрихпунктирной линией показано среднее значение точности предсказания для всех кадров, которое составило 92,23%.

Таким образом, прогнозирование состояния ресурсной сетки линии RB выполняется с высокой точностью. Информация о вероятности наличия и положения свободных блоков SB может быть

использована вторичными пользователями для эффективного встраивания их данных в ресурсную сетку сигнала LTE.

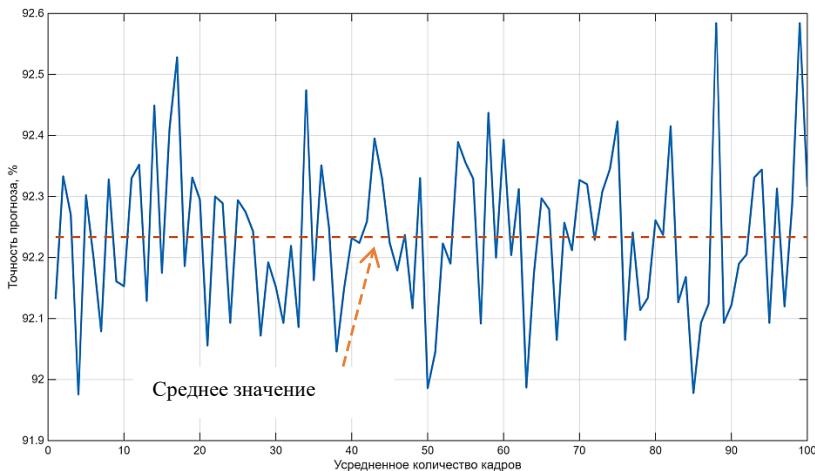


Рис. 10. Оценка точности прогнозирования на основе 100 измерений

Было произведено сравнение точности предсказания моделей KAN и LSTM. Модель KAN обучена со следующими параметрами: количество узлов сетки $G = 60$, порядок сплайна $k = 3$, оптимизатор LBFGS (с ограниченной памятью Брайдена-Флетчера-Гольдфарба-Шанно), среднеквадратичная ошибка для оценки потерь, продолжительность обучения 300 эпох. Корректное сравнение моделей обеспечивалось тем, что число обучаемых параметров для обеих моделей было подобрано одинаковым. Конфигурация слоев модели KAN: {5, 10, 20}; конфигурация слоев LSTM: {5, 57, 20}. В качестве дополнительного эксперимента, после обучения модели KAN выполнена операция обрезки (pruning) с целью удаления узлов, слабо влияющих на результат работы, для повышения быстродействия.

Результаты сравнения показали, что архитектура KAN продемонстрировала точность на 10% выше, чем LSTM, а в процессе обучения значительно быстрее достигла сходимости. Вариант KAN после обрезки увеличил вычислительную эффективность модели на 60% за счет потери точности всего на 2,7%.

Таким образом, была подтверждена эффективность применения архитектуры KAN для прогнозирования занятости частотных ресурсов системы сотовой связи.

7. Заключение. В ходе проведенного исследования была разработана в программной среде MatLab имитационная модель когнитивного радио, которая построена по модульной архитектуре и состоит из трех модулей. Приведено описание основных элементов модулей, особенности их интеграции и применяемые алгоритмы обработки данных.

Модель позволяет генерировать данные REM заданного размера за определенный промежуток времени, задавать количество модулируемых объектов и конфигурировать сценарии их поведения. Используются алгоритмы выявления и предсказания свободных ресурсов на основе искусственной нейронной сети Колмогорова-Арнольда, при этом, за счет гибкой архитектуры, модель позволяет оценивать эффективность других нейросетевых моделей или разрабатываемых алгоритмов определения свободных частотных ресурсов.

Достигнутая точность прогнозирования моделью KAN занятости частотных ресурсов на основе выходных данных имитационной модели системы сотовой связи LTE составила 92,23%. Архитектура KAN показала на 10% более высокую точность в сравнении с LSTM. Полученные результаты открывают перспективы для дальнейших исследований в области когнитивного радио. В частности, возможны разработки более сложных алгоритмов машинного обучения, способных адаптироваться к динамическим изменениям спектра. Также важно изучить возможность интеграции предложенной модели с сетями 5G и IoT, что позволит расширить ее применение.

Литература

1. Зуев А.В. Распределение канальных ресурсов в когнитивной радиосети на основе аукционного метода управления доступом к среде передачи // Системы управления связи и безопасности. 2019. № 3. С. 14–32.
2. Головской В.А. Математическая модель функционирования когнитивной радиосистемы // Журнал Радиоэлектроники. 2024. № 3. С. 1–20. DOI: 10.30898/1684-1719.2024.3.4.
3. Hilal W., Gadsden S.A., Yawney J. Cognitive Dynamic Systems: A Review of Theory, Applications, and Recent Advances // Proc. IEEE. 2023. vol. 111. no. 6. pp. 575–622.
4. Feng B., Zheng M., Liang W., Zhang L. A Recent Survey on Radio Map Estimation Methods for Wireless Networks // Electronics. 2025. vol. 14. no. 8. DOI: 10.3390/electronics14081564.
5. Koutlia K., Bojović B., Lagén S., Giupponi L. Novel radio environment map for the ns-3 NR simulator // Proceedings of the Workshop on ns-3. 2023. pp. 41–48. DOI: 10.1145/3460797.3460803.

6. Gao Y., Niu L., Wang X., Wang T., Chen B. A REM Based Localization Method of Emitter Outside the Sensing Boundary // Advances in Computer and Materials Science Research. 2025. № 2. pp. 209–214.
7. Адамовский Е.Р., Чертков В.М., Богуш Р.П. Модель формирования карты радиосреды для когнитивной системы связи на базе сотовой сети LTE // Компьютерные исследования и моделирование. 2022. Т. 14. № 1. С. 127–146.
8. Арефьев А.С., Варыгин А.А., Фокин Г.А. Анализ структуры целевого сигнала NR и LTE на основе нейросетевого подхода и методов глубокого обучения // Информационные технологии и телекоммуникации. 2024. Т. 12. № 1. С. 16–28. DOI: 10.31854/2307-1303-2024-12-1-16-28.
9. Чертков В.М., Богуш Р.П., Адамовский Е.Р. Модель разделения данных пользователей в когнитивной системе связи на базе LTE // Информационно-управляющие системы. 2023. № 5(126). С. 43–54.
10. Kandaurova E.O. Chirov D.S. Neural Network Algorithm for Predicting Spectrum Occupancy in Cognitive Radio Systems // 2023 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO). 2023. pp. 1–5.
11. Fischer T., Sterling M., Lessmann S. Fx-spot predictions with state-of-the-art transformer and time embeddings // Expert Syst. Appl. 2024. no. 249. pp. 1–11.
12. Адамовский Е.Р., Богуш Р.П., Наумович Н.М. Прогнозирование занятости частотного ресурса в системе когнитивного радио с использованием нейронной сети Колмогорова – Арнольда // Компьютерные исследования и моделирование. 2025. Т. 17. № 1. С. 109–123.
13. Chaves-Villota A., Viteri-Mera C.A. DeepREM: Deep-Learning-Based Radio Environment Map Estimation from Sparse Measurements // IEEE Access. 2023. vol. 11. pp. 48697–48714.
14. Specification TS 36.101. Evolved Universal Terrestrial Radio Access (E-UTRA); User Equipment (UE) radio transmission and reception. URL: <https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=2411> (дата обращения: 12.05.2025).
15. Official web site of crowd-sourced cellular tower and coverage mapping service. URL: https://www.cellmapper.net/First_Time_Startup (дата обращения: 12.05.2025).
16. Богуш Р.П., Адамовский Е.Р., Чертков В.М. Состав и представление данных для модели когнитивной системы связи на базе LTE // Вестник Полоцкого Государственного Университета Серия С Фундаментальные Науки. 2021. № 12. С. 13–20.
17. Адамовский Е.Р., Богуш Р.П., Чертков В.М., Наумович Н.М., Стежко И.К. Моделирование поведения абонентов с использованием цепи Маркова при формировании карты радиосреды для когнитивной системы связи // Вестник Полоцкого Государственного Университета Серия С Фундаментальные Науки. 2022. № 11. С. 8–15.
- 18.

Чертков Валерий Михайлович — канд. техн. наук, доцент, заведующий кафедрой, кафедра технологий программирования, Полоцкий государственный университет имени Евфросинии Полоцкой. Область научных интересов: цифровая обработка сигналов, прикладная теория кодирования, защита информации, встраиваемые микропроцессорные системы, искусственный интеллект. Число научных публикаций — 110. v.chertkov@psu.by; улица Василевцы, 14, 211501, Новополоцк, Беларусь; р.т.: +375(214)599-588.

Богуш Рихард Петрович — д-р техн. наук, доцент, заведующий кафедрой, кафедра вычислительных систем и сетей, Полоцкий государственный университет имени

Евфросинии Полоцкой. Область научных интересов: интеллектуальные и когнитивные системы, машинное обучение, обработка и анализ видеоданных, информационная безопасность. Число научных публикаций — 220. r.bogush@psu.by; улица Якуба Колоса, 6, 211440, Новополоцк, Беларусь; р.т.: +375(214)599-587.

Адамовский Егор Русланович — старший преподаватель, кафедра вычислительных систем и сетей, Полоцкий государственный университет имени Евфросинии Полоцкой. Область научных интересов: цифровая обработка сигналов, техническая защита информации, компьютерное зрение. Число научных публикаций — 45. e.adamovsky@psu.by; улица Хруцкого, 20, 211416, Полоцк, Беларусь; р.т.: +375(333)874-689.

Рогулов Владимир Сергеевич — аспирант, старший преподаватель, кафедра технологий программирования, Полоцкий государственный университет имени Евфросинии Полоцкой. Область научных интересов: разработка программного обеспечения. Число научных публикаций — 5. v.rogulev@psu.by; улица Молодежная, 105, 211448, Новополоцк, Беларусь; р.т.: +375(214)599-588.

V. CHERTKOV, R. BOHUSH, Y. ADAMOVSKIY, V. ROGULEV
SIMULATION MODEL OF COGNITIVE RADIO

Chertkov V., Bohush R., Adamovskiy Y., Rogulev V. Simulation Model of Cognitive Radio.

Abstract. The growing shortage of radio frequency spectrum, driven by the explosive increase in the number of wireless devices and data traffic volumes, makes Cognitive Radio (CR) technologies critically important for the future of telecommunications. This research addresses the challenge of dynamic spectrum management by developing a simulation model of a cognitive radio communication system based on the LTE network architecture. In contrast to existing solutions, the proposed model features a modular structure, allowing for the flexible integration and evaluation of various frequency resource occupancy prediction algorithms. The model is implemented in the MatLab environment and comprises three key modules: an LTE signal generation and processing module, which creates Radio Environment Maps (REM); a predictive neural network model training module; and a frequency resource occupancy prediction module. Particular focus is placed on utilizing the advanced Kolmogorov-Arnold Network (KAN) architecture for predicting unused Scheduling Blocks (SBs) within an LTE frame. Simulation results, encompassing 10,000 frames, demonstrated the high efficiency of the proposed approach. The KAN model achieved a prediction accuracy of 92.23% for identifying free frequency resources in a 10 ms frame. Comparative testing revealed that the KAN architecture outperforms the traditional LSTM network in accuracy by approximately 10% given an equal number of trainable parameters, and also converges faster during training. The practical significance of this work lies in providing a tool for accurate spectrum occupancy assessment and secondary user access planning, leading to a significant increase in the spectral efficiency and reliability of next-generation wireless networks.

Keywords: cognitive radio, simulation model, LTE, spectrum prediction, Kolmogorov-Arnold Network (KAN), Radio Environment Map (REM), dynamic spectrum access.

References

1. Zuev A.V. [Channel resources distribution based on the auction method of controlling access to the transmission medium in a cognitive radio network]. Sistemy upravlenija svjazi i bezopasnosti – Systems of Control, Communication and Security. 2019. no. 3. pp. 14–32. (In Russ.).
2. Golovskoy V.A. [Mathematical model of functioning cognitive radio system]. Zhurnal Radioelektroniki – Journal of Radio Electronics. 2024. no. 3. pp. 1–20. DOI: 10.30898/1684-1719.2024.3.4. (In Russ.).
3. Hilal W., Gadsden S.A., Yawney J. Cognitive Dynamic Systems: A Review of Theory, Applications, and Recent Advances. Proc. IEEE. 2023. vol. 111. no. 6. pp. 575–622.
4. Feng B., Zheng M., Liang W., Zhang L. A Recent Survey on Radio Map Estimation Methods for Wireless Networks. Electronics. 2025. vol. 14. no. 8. DOI: 10.3390/electronics14081564.
5. Koutlia K., Bojović B., Lagén S., Giupponi L. Novel radio environment map for the ns-3 NR simulator. Proceedings of the Workshop on ns-3. 2023. pp. 41–48. DOI: 10.1145/3460797.3460803.
6. Gao Y., Niu L., Wang X., Wang T., Chen B. A REM Based Localization Method of Emitter Outside the Sensing Boundary. Advances in Computer and Materials Science Research. 2025. № 2. pp. 209–214.

7. Adamovskiy Y.R., Chertkov V.M., Bohush R.P. [Model for building of the radio environment map for cognitive communication system based on LTE]. Komp'juternye issledovaniya i modelirovaniye – Computer Research and Modeling. 2022. vol. 14. no. 1. pp. 127–146. (In Russ.).
8. Arefev A., Varygin A., Fokin G. Analysis of NR and LTE Target Signal Structure Based on Neural Network Approach and Deep Learning Methods. Telecom IT. 2024. vol. 12. no. 1. C. 16–28. DOI: 10.31854/2307-1303-2024-12-1-16-28. (In Russ.).
9. Chertkov V.M., Bohush R.P., Adamovskiy Y.R. User data separation model in an LTE-based cognitive communication system. Informatzionno-upravliaushchie sistemy – Information and Control Systems. 2023. no. 5(126). pp. 43–54. (In Russ.).
10. Kandaurova E.O. Chirov D.S. Neural Network Algorithm for Predicting Spectrum Occupancy in Cognitive Radio Systems. 2023 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO). 2023. pp. 1–5.
11. Fischer T., Sterling M., Lessmann S. Fx-spot predictions with state-of-the-art transformer and time embeddings. Expert Syst. Appl. 2024. no. 249. pp. 1–11.
12. Adamovskiy Y.R., Bohush R.P., Naumovich N.M. Prediction of frequency resource occupancy in a cognitive radio system using the Kolmogorov – Arnold neural network. Komp'juternye issledovaniya i modelirovaniye – Computer Research and Modeling. 2025. vol. 17. no. 1. pp. 109–123. (In Russ.).
13. Chaves-Villota A., Viteri-Mera C.A. DeepREM: Deep-Learning-Based Radio Environment Map Estimation from Sparse Measurements. IEEE Access. 2023. vol. 11. pp. 48697–48714.
14. Specification TS 36.101. Evolved Universal Terrestrial Radio Access (E-UTRA); User Equipment (UE) radio transmission and reception. Available at: <https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=2411> (accessed: 12.05.2025).
15. Official web site of crowd-sourced cellular tower and coverage mapping service. Available at: https://www.cellmapper.net/First_Time_Startup (accessed: 12.05.2025).
16. Bohush R.P., Adamovskiy Y.R., Chertkov V.M. [Data Composition and Representation for Cognitive Communication System Model Based on LTE]. Vestnik Polockogo Gosudarstvennogo Universiteta Serija C Fundamental'nye Nauki – Vestnik of Polotsk State University. Part C. Fundamental Sciences. 2021. no. 12. pp. 13–20. (In Russ.).
17. Adamovskiy Y., Bohush R., Chertkov V., Naumovich N., Stegko I. [User Activity Modeling Based on Markov Chain for Radio Environment Map in Cognitive Radio Networks]. Vestnik Polockogo Gosudarstvennogo Universiteta Serija C Fundamental'nye Nauki – Vestnik of Polotsk State University. Part C. Fundamental Sciences. 2022. no. 11. pp. 8–15. (In Russ.).

Chertkov Valery — Ph.D., Associate Professor, Head of the department, Department of software engineering, Euphrosyne Polotskaya State University of Polotsk. Research interests: digital signal processing, applied coding theory, information security, embedded microprocessor systems, artificial intelligence. The number of publications — 110. v.chertkov@psu.by; 14, Vasilevtsy St., 211501, Novopolotsk, Belarus; office phone: +375(214)599-588.

Bohush Rykhard — Ph.D., Dr.Sci., Associate Professor, Head of the department, Department of computing systems and networks, Euphrosyne Polotskaya State University of Polotsk. Research interests: intelligent and cognitive systems, machine learning, video data processing and analysis, information security. The number of publications — 220. r.bogush@psu.by; 6, Yakuba Kolosa St., 211440, Novopolotsk, Belarus; office phone: +375(214)599-587.

Adamovskiy Yahor — Senior Lecturer, Department of computing systems and networks, Euphrosyne Polotskaya State University of Polotsk. Research interests: digital signal processing, technical information security, computer vision. The number of publications — 45. e.adamovsky@psu.by; 20, Khrutskogo St., 211416, Polotsk, Belarus; office phone: +375(333)874-689.

Rogulev Vladimir — Postgraduate Student, Senior Lecturer, Department of software engineering, Euphrosyne Polotskaya State University of Polotsk. Research interests: software development. The number of publications — 5. v.rogulev@psu.by; 105, Molodezhnaya St., 211448, Novopolotsk, Belarus; office phone: +375(214)599-588.

I. FILIANIN, A. KAPITONOV, A. TIMOSHCHUK- BONDAR

**RESEARCH ON REINFORCEMENT LEARNING ALGORITHMS
FOR NETWORK LATENCY REDUCTION IN EDGE COMPUTING**

Filianin I., Kapitonov A., Timoshchuk-Bondar A. Research on Reinforcement Learning Algorithms for Network Latency Reduction in Edge Computing.

Abstract. Current research on decision-making algorithms in multi-access edge computing (MEC) for resource allocation often relies on simplified network topology abstractions, which limits the applicability of the results in real-world mobile network operations. This work aims to develop a realistic cellular network model using stochastic geometry methods and to comprehensively evaluate the effectiveness of modern reinforcement learning algorithms in minimizing network latency in edge computing. To create a mathematically sound model of the network environment, we used stochastic geometry methods combined with real statistical data on cellular user distribution. Applying stochastic geometry ensured accurate modeling of the spatial placement of base stations and the calculation of inter-node distances, which are critically important for determining network latency. Experimental evaluation was conducted on a refined Lightweight MEC Platform Simulator (LWMECPS) platform with an extended Gymnasium API, supporting Proximal Policy Optimization (PPO), Twin Delayed Deep Deterministic Policy Gradient (TD3), and Soft Actor-Critic (SAC) algorithms. We developed a communication network model that considers the realistic spatial distribution of network elements and the temporal dynamics of user load. Based on this model, a virtualized test environment was created in LWMECPS, allowing for reproducible experiments with controllable parameters. Experimental results revealed distinct performance characteristics across the algorithms: PPO achieved a consistent latency reduction of up to 20% with stable convergence; SAC demonstrated the highest absolute improvement (a latency reduction of 38%) but exhibited initialization instability; TD3 showed moderate effectiveness (an improvement of up to 11%) but high sensitivity to hyperparameter tuning. The comparative analysis of reinforcement learning algorithms revealed key features of their application in MEC systems. The discrete nature of service placement tasks makes PPO the most suitable for practical implementation due to its convergence stability and natural support for discrete action spaces, despite SAC achieving higher peak performance. While SAC's superior absolute results are promising, its initialization challenges and original design for continuous action spaces require additional consideration for MEC deployment. The obtained results provide scientifically sound recommendations for MEC platform developers regarding the selection of optimal algorithmic solutions based on specific system requirements and constraints.

Keywords: reinforcement learning, multi-access edge computing (MEC), proximal policy optimization (PPO), soft actor-critic (SAC), twin delayed deep deterministic policy gradient (TD3), LWMECPS, Weights & Biases (WandB).

1. Introduction. Mobile Edge Computing (MEC) represents a distributed computing paradigm that brings data processing and service provision closer to end users, thereby minimizing data transmission delays and reducing the load on central cloud infrastructures [1]. The task of placing computing services in an MEC environment is a multi-criteria optimization problem, whose main objectives are:

- minimization of network latency [2];

- optimization of computational and network resource utilization [3];
- adaptation to data consumption conditions [4];
- energy efficiency [5].

In the first half of 2025, approximately 3,850 scientific articles indexed in Google Scholar discussed algorithms used in decision-making systems for MEC platforms. The core of these decision-making systems for placing computing services in MEC platforms, thus enabling data processing closer to end users, relies on various methods that can be broadly categorized as follows:

- optimization algorithms – they include exact and approximate methods for finding the best solutions in the service placement space;
- reinforcement learning algorithms – used for adaptive selection of placement strategies in dynamically changing environment conditions;
- statistical and heuristic methods – covering a wide range of approaches, including greedy algorithms, dynamic programming methods, and other heuristics that ensure acceptable solution quality with limited computational resources.

The choice of a specific decision-making method depends on the network representation model with MEC architecture. For instance, in the article [6], the communication network is presented in a simplified form as a set of computing nodes and tasks, without considering network parameters and inter-service interactions.

Meanwhile, the works [7] demonstrate the importance of considering multipath transmissions and traffic management in switching nodes to ensure timely packet delivery, which is critically important for minimizing latency in MEC systems.

The article [8] addresses the issue of determining the optimal placement of optical fiber for wave division multiplexing and passive optical network technologies, which enables the reduction of network latency and raises particular questions about the technology's practical applicability.

The article [9] represents the communication network as an RAN cascaded with a computer-server network, with stochastic geometry methods to calculate user and tower placement, which enables the calculation of the Signal-to-Interference Ratio (SIR) and most network communication abstractions.

After analyzing the articles, we can conclude that most of them attempt to represent the communication network mathematically. However, it is worth noting that the radio channel can use various communication standards, such as 4G, 5G, and subsequent generations. These standards, despite their general conceptual direction, are not interchangeable. Furthermore, the implementation of standards varies significantly depending on the equipment manufacturer. Even within the same manufacturer and device series, different hardware

platforms and specialized software can be used, which directly affects the characteristics of data transmission and processing in an MEC system. This, in turn, can significantly impact the quality of decisions made in MEC platforms.

The key optimization criteria when placing computing services are:

- minimizing network latency;
- reducing the cost of deploying and operating services (FinOps approaches);
- reducing the carbon footprint;
- improving user perception of quality of experience (QoE).

These criteria correlate with the parameters used to evaluate the effectiveness of the computational approaches discussed earlier. The scientific literature contains many works aimed at optimizing each of these criteria individually or in combination.

The purpose of this work was to develop a system for training and testing reinforcement learning algorithms in tasks of reducing the average network latency under conditions similar to real-world scenarios.

The objectives defined within this work are as follows:

- analyze the literature and select reinforcement learning algorithms for the decision-making system;
- refine LWMECPS with a gymnasium capability API to support new reinforcement learning algorithms;
- develop a test application that can generate loads based on specified parameters to conduct an experiment;
- conduct an experiment and evaluate reinforcement learning algorithms in a system that approximates a real-world environment.

As a result of this work, we obtained data on the influence of the network model on the performance of reinforcement learning algorithms in the task of placing computing services while reducing the average network latency.

2. Literature Review. The use of reinforcement learning algorithms in decision-making tasks for placing computing services is very popular. However, there are also algorithmic solutions, such as the Lyapunov function discussed in the article [10].

The problem with algorithmic solutions [11] is their strict dependence on the network model, which is rather difficult to describe in the context of real-world communication networks. The advantage of reinforcement learning algorithms is their independence from a specific network model, which can, in turn, accelerate the process of implementing decision-making systems in real cellular networks.

Developing solutions based on RL algorithms is accompanied by difficulties in organizing the test environment used for training models and

prototyping specific solutions [12]. Previously, as a solution to this problem, a Gymnasium capability API interface was developed within the LightWeight Multi Access Edge Computing Platform Simulator, allowing for the rapid organization of an interface for interaction with the target system [13].

Unfortunately, it only supported Q-Network and Deep Q-Network algorithms in a limited representation. Recently, several new reinforcement learning algorithms have emerged that can improve the quality of decisions made.

In particular, new-generation algorithms such as Proximal Policy Optimization (PPO), Soft Actor-Critic (SAC), and Twin Delayed Deep Deterministic Policy Gradient (TD3) address specific problems of dynamic MEC environments and offer significant improvements over traditional Q-learning-based approaches.

These algorithms were developed with the unique characteristics of resource management tasks in edge computing in mind: high variability of environment states, the need for continuous learning under changing load patterns, and requirements for the stability and predictability of decisions when deployed in real-world operations.

Each algorithm is examined below.

The SAC algorithm is an off-policy actor-critic method with an entropy regularizer that trains a stochastic policy, automatically balancing between optimal convergence and exploration of the action space [14]. A key feature of SAC is the inclusion of an entropy term in the objective function, which promotes diversity in action selection and prevents premature convergence to suboptimal solutions. This approach ensures the most stable convergence under noisy reward signals, which is typical for real MEC systems.

In the context of service placement tasks, SAC demonstrates an ability to discover rare and non-standard placement solutions due to its tendency to explore unusual actions. It is especially valuable in scenarios where clusters of edge nodes are subject to abrupt changes, for example, during traffic spikes, unexpected resource constraints on nodes, or sudden equipment failures. The stochastic nature of the SAC policy enables the system to adapt to unforeseen situations by identifying alternative service placement paths overlooked by deterministic approaches.

The TD3 algorithm is an improved version of the DDPG algorithm – an off-policy deterministic actor-critic method. It includes three key improvements aimed at increasing training stability and the quality of the resulting solutions [15]: the first improvement is the use of two Q-networks («twin» Q-networks), which helps to mitigate the problem of overestimating action values typical of critic-based methods; the second

improvement is delayed actor updates performed less frequently than critic updates, contributing to greater stability in the training process; the third improvement – target policy smoothing – adds controlled noise to the actions of the target policy, thereby reducing overfitting to noise in the data.

A special feature of TD3 is its efficient use of samples from the experience buffer, which makes the algorithm economical in terms of data requirements. In MEC tasks, this property manifests itself in high resilience to noise in performance metrics and network parameters. TD3 is particularly well-suited for fine-tuning continuous placement parameters, such as CPU allocation, RAM allocation, and CPU affinity settings, which require precise control over continuous actions without sharp fluctuations in strategy.

The PPO algorithm is an on-policy method that features a «clipping» mechanism to constrain policy updates, preventing radical changes in strategy in a single training step [16]. This ensures a monotonic improvement in performance and high stability in the training process. The algorithm is known for its simple hyperparameter tuning and very rarely exhibits catastrophic training failures («gradient explosions» or sharp degradations in policy quality).

Although PPO requires more data for training compared to off-policy methods, it provides a highly predictable training dynamic and is well-suited for parallelization, which makes it attractive for large-scale MEC deployments. In the context of service placement, a key advantage of PPO is its «gentle» policy update, which protects against sudden degradations in service level objectives (SLOs) when deploying a model in an online environment. While other algorithms might show significant performance drops during fine-tuning or adaptation to new conditions, PPO ensures smooth transitions and stable maintenance of service quality.

Based on this analysis, traditional Q-learning and DQN methods demonstrate significant limitations in the context of MEC systems. Q-learning is effective only for environments with a small and finite number of states, but it struggles with large or continuous state spaces. Meanwhile, DQN suffers from overestimation problems and exhibits unstable convergence [17].

A fundamental drawback of these approaches is their inability to effectively handle continuous space, which is critical for precise resource management in edge computing. Modern algorithms, including SAC, TD3, and PPO, overcome these limitations, providing more stable training and efficient performance in the high-dimensional continuous state and action spaces typical of MEC environments.

3. Decision-Making Methods for Reducing Network Latency in Edge Computing. In the context of edge computing, as previously mentioned, the decision of where to place computing services is a multidimensional

optimization task that requires accounting for many interconnected factors of the network infrastructure. As shown in previous sections, existing approaches to modeling MEC environments often use simplified abstractions of network topology, which limits the applicability of the results in real-world operational conditions.

A key problem in current research is the insufficiently accurate representation of the spatial distribution of network infrastructure elements and the dynamics of user load. The use of stochastic geometry methods is necessary to define a model for the physical location of cellular towers and to determine the distance between them, which is critical for accurately calculating network latencies and radio signal quality.

Traditional approaches to modeling MEC environments rely on deterministic topologies or overly simplistic probabilistic models that do not reflect the real complexity of modern cellular networks. All this leads to the generation of training data that can differ significantly from real-world conditions, which, in turn, reduces the quality of trained RL models deployed in a production environment.

This section presents an approach to creating a more realistic MEC environment model based on integrating stochastic geometry methods with a practical simulation platform. We hypothesize that the use of stochastic geometry methods to calculate the UE per BS distribution in combination with a realistic LWMECPS environment based on Minikube will improve the quality of RL algorithm training by providing higher-quality data.

The proposed approach aims to overcome the limitations of existing methods by creating a hybrid model that combines the mathematical rigor of stochastic modeling with the practical applicability of containerized computing environments. This allows for the creation of a test environment that maintains the controllability and reproducibility of experiments while ensuring a high degree of correspondence to the real-world operating conditions of MEC systems.

We can represent the environment under investigation in a general form as:

$$State_t = \{Node_t^1, Node_t^2, \dots, Node_t^i, Deployment_t^i, AvgLatency\}, \quad (1)$$

where

$$Node_t^i = \{CPU_t^i, RAM_t^i, TX_t^i, RX_t^i\}, \quad i = 1, 2, 3, \dots, n, \quad (2)$$

$$\begin{aligned} Deployment_t^i = \{ & CPU_usage_t^i, \\ & RAM_usage_t^i, \\ & TX_usage_t^i, \\ & RX_usage_t^i, \\ & Replicas_t^i \}, \end{aligned} \quad (3)$$

then we can represent the action as

$$Action_t = \{Replicas_t^1, Replicas_t^2, \dots, Replicas_t^i\}, \quad i = 1, 2, 3, \dots, n, \quad (4)$$

where

$$Replicas_t^i \in [0, R_{\max}], \quad (5)$$

and R_{\max} is the maximum number of replicas per deployment.

$$Imbalance_r = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i^r - \bar{x}^r)^2}. \quad (6)$$

The following section examines each machine learning algorithm individually.

To describe Proximal Policy Optimization for network latency reduction tasks, we can represent the system state at discrete time points $t = 0, 1, \dots, T$ as:

$$\begin{aligned} s_t = \Big\{ & Node_t^{(1)}, \dots, Node_t^{(n)}, \\ & Deployment_t^{(1)}, \dots, Deployment_t^{(n)}, \\ & AvgLatency_t \Big\}, \end{aligned} \quad (7)$$

where

$$Node_t^{(i)} = \left(CPU_t^{(i)}, RAM_t^{(i)}, TX_t^{(i)}, RX_t^{(i)} \right), \quad (8)$$

are the remaining resources of the i -th node;

$$Deployment_t^{(i)} = \left(CPU_usage_t^{(i)}, RAM_usage_t^{(i)}, TX_usage_t^{(i)}, RX_usage_t^{(i)}, Replicas_t^{(i)} \right), \quad (9)$$

and $AvgLatency_t$ is the moving average of the response latency.

Agent's action:

$$a_t = \left(Replicas_t^{(1)}, \dots, Replicas_t^{(n)} \right), \quad Replicas_t^{(i)} \in \{0, \dots, R_{\max}\}. \quad (10)$$

It is a multimodal discrete value (Multi-Discrete action space) that determines the new number of replicas for each deployment, while the reward function linearly combines metrics:

$$R_t = -\alpha AvgLatency_t - \beta \sum_{i=1}^n Replicas_t^{(i)} - \gamma \sum_{r \in \{CPU, RAM, TX, RX\}} Imbalance_t^{(r)}, \quad (11)$$

where $\alpha, \beta, \gamma > 0$ are the weights chosen empirically for the target «quality/cost» ratio.

An agent in PPO learns to find a stochastic policy as follows:

$$\pi_{\theta}(a_t | s_t) = \prod_{i=1}^n \pi_{\theta}^{(i)}(Replicas_t^{(i)} | s_t). \quad (12)$$

This is parameterized by a «shared neural network head» θ . Factorization by i simplifies the approximation of an enormous action space $(R_{\max} + 1)^n$. The state is evaluated by a critic $V_{\phi}(s_t)$ with parameters ϕ .

After collecting a batch of trajectories of length T , we fix the old policy $\pi_{\theta_{old}}$ and calculate the probability ratio:

$$r_t(\theta) = \frac{\pi_{\theta}(a_t|s_t)}{\pi_{\theta_{old}}(a_t|s_t)}. \quad (13)$$

For a more stable gradient step, a clipped surrogate objective is used:

$$L_{\text{clip}}(\theta) = \hat{\mathbb{E}}_t \left[\min \left(r_t(\theta) \hat{A}_t, \text{clip}(r_t(\theta), 1 - \varepsilon, 1 + \varepsilon) \hat{A}_t \right) \right], \quad (14)$$

where $\varepsilon \in [0.1, 0.3]$ is a hyperparameter and \hat{A}_t is an advantage estimate.

We also use a generalized advantage estimate (GAE- λ):

$$\hat{A}_t = \sum_{k=0}^{T-t-1} (\gamma \lambda)^k (R_{t+k} + \gamma V_{\phi}(s_{t+k+1}) - V_{\phi}(s_{t+k})), \quad (15)$$

with discounting $\gamma \in (0, 1)$ and a smoothing parameter $\lambda \in [0, 1]$.

The overall loss function, which is optimized using the stochastic gradient method, also includes the critic's loss and an entropy regularization term:

$$L(\theta, \phi) = -L_{\text{clip}}(\theta) + c_v \hat{\mathbb{E}}_t [(V_{\phi}(s_t) - R_t)^2] - c_s \hat{\mathbb{E}}_t [\mathcal{H}(\pi_{\theta}(\cdot|s_t))], \quad (16)$$

where

$$R_t = \sum_{k=0}^{T-t-1} \gamma^k R_{t+k}, \quad (17)$$

\mathcal{H} is the policy entropy, and $c_v, c_s > 0$ are coefficients.

The condition «node resources are not exceeded» ($CPU_usage_t^{(i)} \leq CPU_t^{(i)}$, etc.) is implemented through masking. Forbidden components $\hat{A}_t^{(i)}$ are assigned a zero probability before sampling, which ensures the correctness of $r_t(\theta)$. This strategy is compatible with the PPO formulation and does not violate the requirements of a monotonic policy. Algorithm 1 displays the sequence of actions for PPO training.

Algorithm 1. Proximal Policy Optimization (PPO) with Clipped Objective

- 1: **Input:** Initial policy parameters θ , value function parameters ϕ ; clipping threshold ε ; number of epochs K ; mini-batch size B ; horizon T ; learning rates η_θ , η_ϕ ; discount factor γ ; GAE parameter λ
 - 2: **while** not converged **do**
 - 3: Collect trajectories $\{(s_t, a_t, r_t, s_{t+1})\}$ for T timesteps using current policy π_θ
 - 4: Compute advantage estimates \hat{A}_t using GAE:
- $$\delta_t = r_t + \gamma V_\phi(s_{t+1}) - V_\phi(s_t), \quad \hat{A}_t = \sum_{l=0}^{\infty} (\gamma \lambda)^l \delta_{t+l}$$
- 5: Compute empirical returns: $\hat{R}_t = \hat{A}_t + V_\phi(s_t)$
 - 6: Compute old log probabilities: $\log \pi_\theta(a_t | s_t)$
 - 7: **for** $k = 1$ to K **do** ▷ Number of policy updates per batch
 - 8: Sample mini-batch of size B from collected data
 - 9: Compute probability ratio:
- $$r_t(\theta) = \frac{\pi_\theta(a_t | s_t)}{\pi_{\theta_{\text{old}}}(a_t | s_t)}$$
- 10: Compute clipped surrogate objective:
- $$\mathcal{L}_\theta^{\text{CLIP}} = \hat{\mathbb{E}}_t [\min(r_t(\theta) \hat{A}_t, \text{clip}(r_t(\theta), 1 - \varepsilon, 1 + \varepsilon) \hat{A}_t)]$$
- 11: Update policy parameters:
- $$\theta \leftarrow \theta + \eta_\theta \nabla_\theta \mathcal{L}_\theta^{\text{CLIP}}$$
- 12: Update value function by minimizing:
- $$\mathcal{L}_V(\phi) = \hat{\mathbb{E}}_t \left[(V_\phi(s_t) - \hat{R}_t)^2 \right]$$
- $$\phi \leftarrow \phi - \eta_\phi \nabla_\phi \mathcal{L}_V(\phi)$$
- 13: **end for**
 - 14: **end while**
 - 15: **Output:** Optimized policy parameters θ

The Soft Actor-Critic algorithm is adapted for discrete multi-action environments in network resource allocation tasks. The policy $\pi_\theta(a_t | s_t)$ is parameterized by a neural network θ that outputs action logits for each deployment dimension. The factorization by i simplifies the approximation of an enormous action space $(R_{\max} + 1)^n$.

The state is evaluated by two critic networks $V_{\phi_1}(s_t)$ and $V_{\phi_2}(s_t)$ with parameters ϕ_1 and ϕ_2 , where the minimum Q-value is used for stability.

Actor-Critic Architecture we can represent like this:

- **Actor Network:** Outputs logits for categorical distribution over replica counts $[0, R_{\max}]$ for each deployment;
 - **Critic Network:** Two Q-networks that estimate $Q(s_t, a_t)$ for state-action pairs;
 - **Target Network:** Soft updates with parameter τ for critic target networks.
- Critic Update: Minimize the Bellman error with entropy regularization:

$$L_{\text{critic}} = \mathbb{E} \left[(Q(s_t, a_t) - (r_t + \gamma (\min Q'(s_{t+1}, a_{t+1}) - \alpha \log \pi(a_{t+1} | s_{t+1}))))^2 \right].$$

Actor Update: Maximize expected reward plus entropy:

$$L_{\text{actor}} = \mathbb{E} [\alpha \log \pi(a_t | s_t) - \min(Q_1(s_t, a_t), Q_2(s_t, a_t))].$$

Temperature Update: Automatic entropy tuning:

$$L_{\alpha} = \mathbb{E} [-\alpha \log \pi(a_t | s_t) - \alpha H_{\text{target}}].$$

Algorithm 2 displays the sequence of actions for SAC training. The Twin Delayed Deep Deterministic Policy Gradient (TD3) algorithm is adapted for discrete multi-action environments in network resource allocation tasks.

The policy $\pi_{\theta}(a_t | s_t)$ is parameterized by a neural network θ that outputs discrete action indices for each deployment dimension. The factorization by i simplifies the approximation of an enormous action space $(R_{\max} + 1)^n$.

The state is evaluated by two critic networks $V_{\phi_1}(s_t)$ and $V_{\phi_2}(s_t)$ with parameters ϕ_1 and ϕ_2 , where the minimum Q-value is used to reduce overestimation bias.

Algorithm 2. Soft Actor-Critic (SAC)

1: **Input:** Policy parameters θ , critic parameters ϕ_1, ϕ_2 , target networks $\bar{\phi}_1 \leftarrow \phi_1$, $\bar{\phi}_2 \leftarrow \phi_2$, temperature coefficient α , discount factor γ , target smoothing coefficient τ , learning rates $\eta_Q, \eta_\pi, \eta_\alpha$, experience replay buffer \mathcal{D}

2: **while** not converged **do**

3: Collect transitions (s_t, a_t, r_t, s_{t+1}) by interacting with the environment using policy $\pi_\theta(a|s)$

4: Store transitions in replay buffer: $\mathcal{D} \leftarrow \mathcal{D} \cup \{(s_t, a_t, r_t, s_{t+1})\}$

5: **for all** mini-batches sampled from \mathcal{D} **do**

6: Sample next action $a_{t+1} \sim \pi_\theta(\cdot|s_{t+1})$

7: Compute target Q-value:

$$y_t = r_t + \gamma \left(\min_{i=1,2} Q_{\bar{\phi}_i}(s_{t+1}, a_{t+1}) - \alpha \log \pi_\theta(a_{t+1}|s_{t+1}) \right)$$

8: Update each critic by minimizing the loss:

$$\phi_i \leftarrow \phi_i - \eta_Q \nabla_{\phi_i} (Q_{\phi_i}(s_t, a_t) - y_t)^2, \quad i = 1, 2$$

9: Update the policy parameters via:

$$\theta \leftarrow \theta - \eta_\pi \nabla_\theta \hat{\mathbb{E}}_{a_t \sim \pi_\theta} \left[\alpha \log \pi_\theta(a_t|s_t) - \min_i Q_{\phi_i}(s_t, a_t) \right]$$

10: If using adaptive temperature, update α :

$$\alpha \leftarrow \alpha - \eta_\alpha \nabla_\alpha \hat{\mathbb{E}}_{a_t \sim \pi_\theta} \left[-\alpha (\log \pi_\theta(a_t|s_t) + \mathcal{H}_{\text{target}}) \right]$$

11: Update target networks:

$$\bar{\phi}_i \leftarrow \tau \phi_i + (1 - \tau) \bar{\phi}_i, \quad i = 1, 2$$

12: **end for**

13: **end while**

14: **Output:** Learned parameters θ, ϕ_1, ϕ_2 , and α

Actor-Critic Architecture:

- **Actor Network:** Outputs discrete action indices via arg max over replica counts $[0, R_{\max}]$ for each deployment;
- **Critic Networks:** Two Q-networks that estimate $Q(s_t, a_t)$ for state-action pairs;
- **Target Networks:** Soft updates with parameter τ for all target networks;

- **Critic Update:** Minimize the Bellman error using twin critics:

$$L_{\text{critic}} = \hat{\mathbb{E}} \left[\left(Q(s_t, a_t) - \left(r_t + \gamma \min \left(\frac{Q'_1(s_{t+1}, \pi'(s_{t+1})),}{Q'_2(s_{t+1}, \pi'(s_{t+1}))} \right) \right)^2 \right] ;$$

- **Actor Update:** Maximize Q-value with policy delay:

$$L_{\text{actor}} = \hat{\mathbb{E}} [-Q_1(s_t, \pi(s_t))].$$

The standard TD3 algorithm has been adapted for discrete action spaces by:

- converting discrete action indices to float for critic networks;
- removing target policy smoothing (not applicable to discrete actions);
- using arg max for action selection instead of continuous outputs;
- adding exploration noise through discrete action perturbation.

Algorithm 3 displays the sequence of actions for TD3 training. Based on the mathematical formulations presented above, the PPO, SAC, and TD3 algorithms were implemented for network latency reduction in Mobile Edge Computing (MEC) environments.

The three algorithms demonstrate distinct characteristics in their approach to policy optimization. PPO employs a clipped surrogate objective with generalized advantage estimation, ensuring stable policy updates. SAC utilizes entropy regularization with automatic temperature tuning to balance exploration and exploitation. TD3 implements twin critics with policy delay mechanisms to reduce overestimation bias and enhance training stability.

In environments with extensive discrete action spaces, methods based on value function learning (such as Q-learning and its modifications) are subject to fundamental scalability limitations. The computational complexity of Q-value updates increases linearly with the size of the action space, while maximization bias increases proportionally to the logarithm of the number of alternatives. Traditional exploration strategies, such as the ϵ -greedy approach and Boltzmann policies, become exponentially less efficient as the cardinality of the action space increases. This results in slower convergence and greater variance in estimates.

Actor-critic methods (Proximal Policy Optimization, Soft Actor-Critic and Twin Delayed Deep Deterministic Policy Gradient) offer architectural solutions to these issues. Direct parametric policy learning eliminates the need to accurately approximate value functions for the entire action space, allowing computational resources to be concentrated on statistically significant regions. Regularization mechanisms – KL divergence in PPO, entropy

constraints in SAC and ensemble critics in TD3 – stabilize learning and mitigate overestimation artifacts. Integrated stochastic exploration strategies implemented through entropy bonuses, stochastic policy parameterization and noise perturbations support effective exploration given the combinatorial complexity of the action space.

Algorithm 3. Twin Delayed Deep Deterministic Policy Gradient (TD3)

1: **Input:** Initial actor parameters θ , critic parameters ϕ_1, ϕ_2 , target networks

$$\bar{\theta} \leftarrow \theta, \quad \bar{\phi}_1 \leftarrow \phi_1, \quad \bar{\phi}_2 \leftarrow \phi_2;$$

exploration noise \mathcal{N} ; target smoothing noise scale σ ; policy update delay d ; learning rates η_Q, η_π ; target update rate τ ; discount factor γ ; replay buffer \mathcal{D}

2: **while** not converged **do**

3: Collect action with exploration: $a_t = \pi_\theta(s_t) + \mathcal{N}_t$

4: Execute a_t , observe r_t, s_{t+1}

5: Store transition (s_t, a_t, r_t, s_{t+1}) in buffer \mathcal{D}

6: **for all** mini-batches sampled from \mathcal{D} **do**

7: Add clipped noise: $\tilde{a}_{t+1} = \pi_{\bar{\theta}}(s_{t+1}) + \varepsilon$, where $\varepsilon \sim \mathcal{N}(0, \sigma)$, clipped to $[-c, c]$

8: Compute target Q-value:

$$y_t = r_t + \gamma \min_{i=1,2} Q_{\bar{\phi}_i}(s_{t+1}, \tilde{a}_{t+1})$$

9: Update critics:

$$\phi_i \leftarrow \phi_i - \eta_Q \nabla_{\phi_i} (Q_{\phi_i}(s_t, a_t) - y_t)^2, \quad i = 1, 2$$

10: **if** iteration % $d == 0$ **then**

11: Update actor (policy gradient):

$$\theta \leftarrow \theta - \eta_\pi \nabla_\theta Q_{\phi_1}(s_t, \pi_\theta(s_t))$$

12: Update target networks:

$$\bar{\phi}_i \leftarrow \tau \phi_i + (1 - \tau) \bar{\phi}_i, \quad \bar{\theta} \leftarrow \tau \theta + (1 - \tau) \bar{\theta}$$

13: **end if**

14: **end for**

15: **end while**

16: **Output:** Trained actor θ and critics ϕ_1, ϕ_2

These reinforcement learning approaches provide a comprehensive framework for adaptive resource management in dynamic MEC environments,

enabling intelligent decision-making for replica allocation that directly impacts network performance and user experience.

4. Limitations. The model considered in this study has certain limitations related to the challenges of emulating processes within a communication network, and these must be taken into account.

For instance, we opted for a uniform distribution with a latency of 10 ms. While this decision may raise questions, there is an explanation. Currently, the absence of straightforward traffic balancing tools within the LWMECPS network hinders the implementation of transitive latencies.

Since their spatial locations are known, we could of course determine the distance between nodes and use simple formulas to calculate the latency between them. However, we must remember that traffic within the network will follow a path formed by an IGP protocol, such as OSPF, EIGRP or IS-IS.

Simultaneously, we utilize the distribution of users in time and space, enabling us to influence network latency by adjusting the load on UEs.

Furthermore, solutions based on SDN, IPIP tunnels and network slicing allow for flexible traffic management. However, these are difficult to account for in all use cases. Therefore, for now, we have decided to use linearly increasing latencies, but we could calculate them more accurately in the future.

5. Development of a System for Evaluating RL Algorithms in Network Latency Reduction Tasks. To practically verify the proposed hypotheses and obtain quantitative estimates of the effectiveness of modern RL algorithms in service placement tasks, it is necessary to create a comprehensive experimental environment.

Such an environment must not only ensure a correct simulation of network conditions approximated to real-world scenarios but also provide tools for a systematic comparison of different decision-making approaches in MEC systems.

Therefore, to organize an experiment that would allow us to test our hypothesis, it was necessary to refine the previously discussed LWMECPS system [13] and develop a test application that could emulate network activity and measure the latency between nodes, with support for experiments and network activity distribution.

We can highlight the following requirements for refining LWMECPS-GYM:

- add support for PPO, SAC, and TD3 RL algorithms;
- add the ability to create experiments with specific parameters for the corresponding machine learning algorithms;
- add the ability to collect data on average latency from the LWMECPS-testapp-client by group_id;

– add the ability to save machine learning models, logs, and metrics to the WandB machine learning model storage system.

In addition, the `lwmecps-testapp` test application had to meet the following requirements:

- ability to configure load parameters;
- support for mechanisms to measure and log performance metrics;
- ability to emulate various user behavior scenarios.

The `lwmecps-testapp` test application is a distributed system designed to investigate the effectiveness of reinforcement learning algorithms when optimizing network latencies in edge computing.

Based on a microservice approach, the system's architecture includes three main components: a client application, a server application, and a data management system based on MongoDB.

The `lwmecps-testapp-client` service is implemented using the FastAPI framework and performs the functions of a load generator and an experiment coordinator. The main functional module includes managing the experiment lifecycle, generating a controlled load, and collecting performance metrics.

The experiment management system enables the creation, initialization, and control of experiment states through REST API endpoints. Each experiment features a set of parameters, including the configuration of target servers, load profiles, and time constraints. Load profiles consist of three parameters (N , T , D), where N is the number of concurrent users, T represents the interval between requests, and D denotes the profile duration.

The load generation module implements an asynchronous architecture using `asyncio`, ensuring high throughput with minimal resource consumption. The system supports up to 100 concurrent tasks with configurable connection timeouts. The latency measurement algorithm includes host prioritization and automatic failover in case of node failure.

The `lwmecps-testapp-server` service emulates the behavior of edge computing nodes under variable load. The server architecture consists of a request processing module, a resource emulation system, and metric export.

The main endpoint `/api/latency` provides latency measurement with a realistic modeling of edge node behavior. The resource emulation system implements synthetic modeling of CPU and RAM usage with configurable resource limits.

Figure 1 shows the architecture of the LWMECPS test setup. LitmusChaos, as discussed in previous articles, is also used as a system for introducing latency.

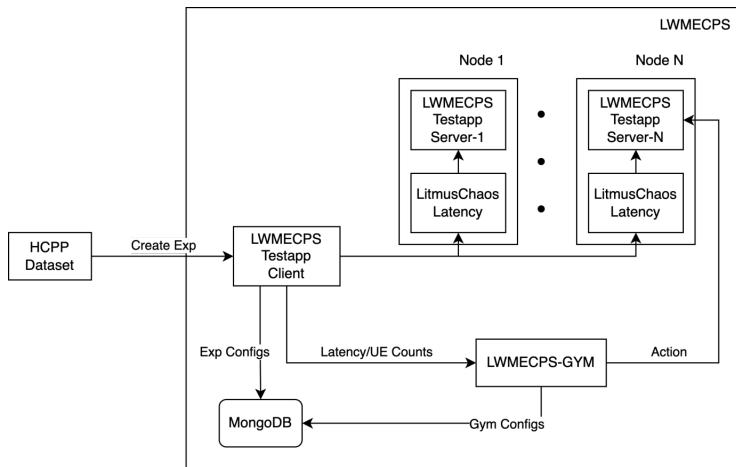


Fig. 1. Architecture of the LWMECPS test setup

As initial data, the user distribution from article [18] was taken and processed through the Hard-Core Poisson Process (HCPP) algorithm to determine the distribution of users per BS, based on the method discussed in [19].

Using the distribution data of BSs and UEs per DB, we formed a user distribution throughout the day based on the previously discussed statistics and created a graph from 00:00 to 23:59 with a 10-second step, as shown in Figure 2 [20].

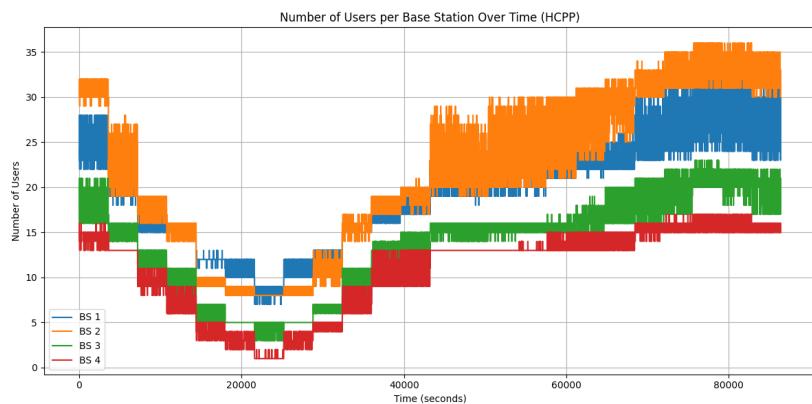


Fig. 2. Distribution diagram of UEs per BS during 1 day

This distribution enables more accurate training of the RL model, allowing it to account for the non-uniform usage of communication networks depending on time. The generated distribution promoted the preparation of experiments for each `lwmecps-testapp-server` deployed on the LWMECPS nodes.

Figure 3 shows the architecture of the `lwmecps-testapp` for experiment 1, from the perspective of the communication network and the introduced latencies.

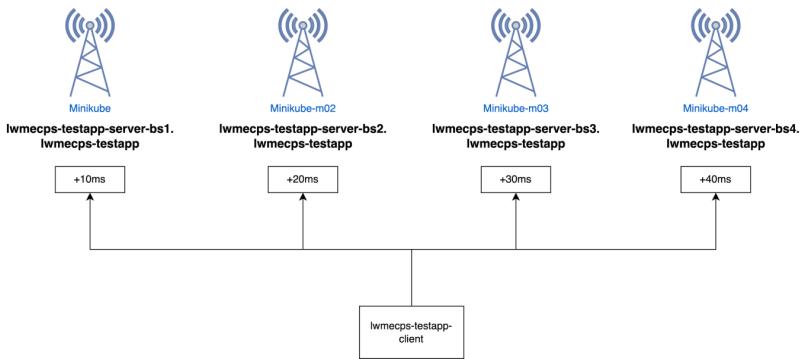


Fig. 3. `lwmecps-testapp` architecture for experiment 1

We must note the problem of transitive latencies. At this stage, it is not possible to implement transitive latencies due to the complexities of modeling traffic flow. However, this problem has the following solution.

The experiment involves 4 BSs, with identifiers `bs_1, ..., bs_4`. Each `bs_n` has a unique load profile and host list. The `lwmecps-testapp-client` algorithm works as follows: if the first `lwmecps-testapp-server` endpoint in the queue is unavailable, it will try the next one. Thus, the location of computing services dynamically changes, and client traffic will flow.

To train the reinforcement learning algorithms, we prepared two network load profiles: from 0 to 21600 seconds (6 hours) and from 0 to 86400 seconds (24 hours). All the RL algorithms were trained on each network load profile for the corresponding duration, allowing us to test not only the quality of the algorithms against each other but also the influence of changing network load over time on the quality of decisions made.

To evaluate the quality of decisions made to reduce network latency, six verification experiments were prepared, each running for 100 episodes. This approach enabled the evaluation of six machine learning models based on three algorithms, all of them trained for 6 and 24 hours.

Figures 4, 5, and 6 show the results of network latency optimization by the PPO, SAC, and TD3 algorithms for models trained for 6 and 24 hours.

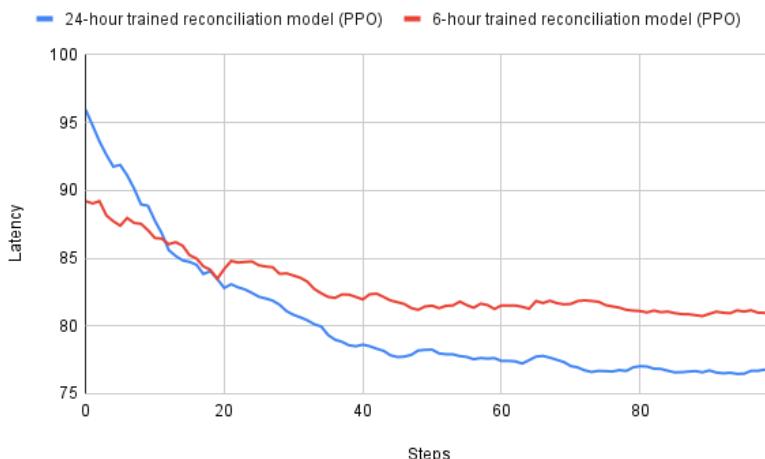


Fig. 4. Network latency optimization graph by PPO algorithm for 6 and 24 hour models

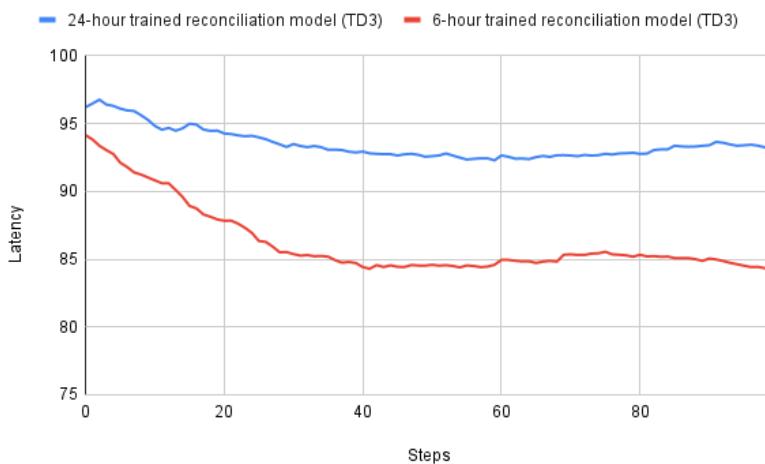


Fig. 5. Network latency optimization graph by TD3 algorithm for 6 and 24 hour models

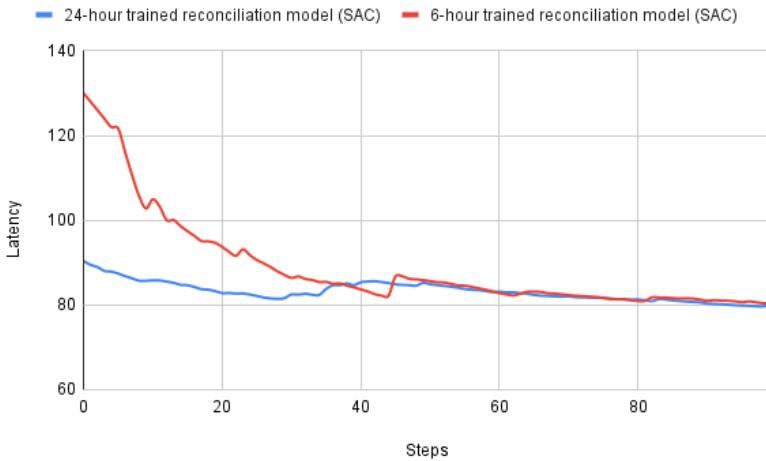


Fig. 6. Network latency optimization graph by SAC algorithm for 6 and 24 hour models

Table 1 shows the numerical results of the comparison of the PPO, SAC, and TD3 models trained for 6 and 24 hours to assess the impact of training duration on the quality of decisions made. For comparison, the initial and final average delay values were taken, as well as their delta in absolute and percentage terms.

Table 1. Comparison of RL algorithms for 6 and 24 hour training

Algorithm	Initial Latency	Final Latency	Absolute Delta (ms)	Percent Change
PPO 6 h	≈ 90 ms	≈ 81 ms	-9	-10%
PPO 24 h	≈ 96 ms	≈ 77 ms	-19	-19%
TD3 6 h	≈ 94 ms	≈ 84 ms	-10	-11%
TD3 24 h	≈ 95 ms	≈ 90 ms	-5	-5%
SAC 6 h	≈ 90 ms	≈ 79 ms	-11	-12%
SAC 24 h	≈ 130 ms	≈ 80 ms	-50	-38%

Based on the analysis of the data in the table, we can draw the following conclusions.

The PPO algorithm trained for 24 hours shows the best performance in network latency reduction, lowering it by nearly 20%. According to the graphs, PPO also has the smoothest trajectory – the latency curve converges to a local minimum and stabilizes quickly.

The TD3 algorithm shows the best latency reduction among 6-hour experiments. However, it shows poor results when trained for 24 hours, with several runs yielding different outcomes. The TD3 algorithm is overly sensitive

to hyperparameters whose influence can significantly alter the experimental results.

The SAC algorithm demonstrates the most dramatic improvement in the 24-hour training scenario, achieving a 38% latency reduction despite starting from a higher initial latency (~ 130 ms). However, the high initial latency suggests potential initialization or early training instability issues that warrant further investigation.

Based on the data obtained, we can conclude that the PPO algorithm is optimal for reducing the average network latency. Unlike robotics or autonomous vehicle systems, which require the fine-tuning of continuous parameters like steering angle or engine power, the task of service placement in an MEC environment is characterized by a discrete action space – selecting a specific node from an available set to deploy a particular service [21]. The SAC algorithm was developed for continuous action spaces [22]. Although modifications exist for discrete tasks [23], they require additional adaptation, which can negatively affect performance [24].

The discreteness of the action space poses significant challenges for policy optimization in deep reinforcement learning methods. The inability to differentiate the argmax operation prevents the use of gradient methods for direct action optimization. Meanwhile, the discrete redistribution of probability mass between actions leads to discontinuous changes in policy. These features exacerbate bootstrap error in critic algorithms and increase sensitivity to inaccuracies in Q-function estimates for rare actions. They also contribute to premature policy determination, which leads to the collapse of state and action space exploration.

We define algorithmic stability as low performance variance across seeds, absence of policy collapse during extended training, stable value estimates and gradients, and robustness to moderate distribution shifts.

PPO exhibits sensitivity to prolonged training through on-policy data reuse. Extended epochs on fixed batches with constant clipping induce batch overfitting, where surrogate improvements fail to translate to reward gains. Additionally, entropy decay despite bonuses leads to deterministic policies with reduced robustness. Our protocol limits epochs to two per batch, monitors adaptive KL divergence, enforces entropy floors, and employs early stopping with validation-based checkpoint selection.

SAC's maximum entropy framework enhances stability by maintaining state coverage. However, automatic temperature adjustment reduces entropy over time, causing determinization and robustness loss. Fixed replay buffers create distribution shifts as aged samples bias Q-functions, while bootstrap artifacts accumulate over extended horizons. Mitigation strategies include

minimum alpha constraints, critic weight decay, Polyak EMA updates, and EMA checkpoint preservation.

TD3's twin critics and target smoothing stabilize early training phases. Extended training can induce conservative Q-underestimation, freezing improvement and amplifying noise sensitivity. Suboptimal Polyak coefficients and update frequencies desynchronize networks, increasing TD-error and reducing replay diversity. Stability is maintained through careful policy delay and target noise control.

In contrast, the PPO algorithm naturally supports both discrete and continuous action spaces, making it more suitable for service placement tasks without architectural modifications.

Understanding the specifics of MEC platforms, we can assert that the requirements characteristic of this domain – convergence stability, resilience to changes in network conditions, and the need to maintain quality of service – align particularly well with the architectural features of PPO. Unlike studies in robotics [25] where algorithm comparisons involve tasks with continuous control, MEC tasks are combinatorial optimization problems with discrete choices. The observed instability of TD3 in the experiments is also explained by the fact that this algorithm, like SAC, is optimized for continuous actions, and its application to discrete tasks can lead to suboptimal behavior.

6. Conclusion. This study conducted a comprehensive analysis of the effectiveness of modern reinforcement learning algorithms – Proximal Policy Optimization (PPO), Twin Delayed Deep Deterministic Policy Gradient (TD3), and Soft Actor-Critic (SAC) – in the task of optimizing service placement to minimize network latency in edge computing.

To ensure the correctness of the experimental studies, we significantly refined the LWMECPS platform by upgrading the Gymnasium API interface to support the investigated machine learning algorithms. Additionally, a comprehensive test environment, `lwmecps-testapp`, was developed to emulate realistic network load scenarios using stochastic geometry methods to model the spatial distribution of base stations and user devices.

The experimental results demonstrate significant differences in the effectiveness of the algorithms:

- The PPO algorithm showed the best results, achieving an average network latency reduction of up to 20% when trained on a 24-hour load profile. PPO's key advantages are its high convergence stability, natural support for discrete action spaces, and resilience to variations in network conditions, making it the most suitable algorithm for practical application in MEC systems.

- The TD3 algorithm demonstrated moderate effectiveness with a maximum latency reduction of 11% for a 6-hour training profile. However,

we revealed a critical sensitivity of the algorithm to hyperparameter tuning, leading to significant variability in results and limiting its practical applicability without meticulous configuration.

– The SAC algorithm demonstrated mixed results: while achieving the highest absolute latency reduction (38%) in extended training scenarios, it exhibited initialization challenges with elevated initial latency values. This behavior is consistent with SAC's original design for continuous action spaces, suggesting that discrete MEC service placement tasks may require additional algorithmic adaptations for optimal performance.

The results obtained confirm the hypothesis that using more realistic models of the network environment, based on stochastic geometry methods, improves the quality of RL algorithm training. This is especially important for ensuring the applicability of the resulting solutions in real-world MEC system operations.

Future work should focus on investigating hybrid approaches that combine the stability of PPO with the exploration capabilities of other algorithms, as well as validating these findings in real MEC testbed environments.

References

1. Cruz P., Achir N, Viana A.C. On the edge of the deployment: A survey on multi-access edge computing. *ACM Computing Surveys*. 2022. vol. 55. no. 5. pp. 1–34. DOI: 10.1145/3529758.
2. Yi Y., Zhang G., Jiang H. Mobile Edge Computing Networks: Online Low-Latency and Fresh Service Provisioning. *IEEE Transactions on Communications*. 2025.
3. Wang K., Akhtar S.F., Al-Zahrani F.A. An Efficient Algorithm for Resource Allocation in Mobile Edge Computing Based on Convex Optimization and Karush–Kuhn–Tucker Method. *Complexity*. 2023. vol. 2023(1). pp. 1–15. DOI: 10.1155/2023/9604454.
4. Qin Y., Chen J., Jin L., Yao R., Gong Z. Task offloading optimization in mobile edge computing based on a deep reinforcement learning algorithm using density clustering and ensemble learning. *Scientific Reports*. 2025. vol. 15. no. 1. DOI: 10.1038/s41598-024-84038-3.
5. Rodríguez-Liria A.F., Cárdenas R., Arroba P., Moya J.M., Risco-Martín J.L., Wainer G. Decision Support Framework for Automating the Optimization of Edge Computing Federations. *Proceedings of 2023 Annual Modeling and Simulation Conference (ANNSIM)*. 2023. pp. 49–60.
6. Liu J., Ren J., Zhang Y., Peng X., Zhang Y., Yang Y. Efficient Dependent Task Offloading for Multiple Applications in MEC-Cloud System. *IEEE Transactions on Mobile Computing*. 2021. vol. 22. no. 4. pp. 2147–2162. DOI: 10.1109/TMC.2021.3119200.
7. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Control of multipath transmissions in the nodes of switching segments of reserved paths. *Proceedings of International Conference on Information, Control, and Communication Technologies (ICCT)*. 2022. pp. 1–5.
8. Wang X., Ji Y., Zhang J., Bai L., Zhang M. Low-Latency Oriented Network Planning for MEC-Enabled WDM-PON Based Fiber-Wireless Access Networks. *IEEE Access*. 2019. vol. 7. pp. 183383–183395. DOI: 10.1109/ACCESS.2019.2926795.

9. Ko S.-W., Han K., Huang K. Wireless Networks for Mobile Edge Computing: Spatial Modeling and Latency Analysis. *IEEE Transactions on Wireless Communications*. 2018. vol. 17. no. 8. pp. 5225–5240. DOI: 10.1109/TWC.2018.2840120.
10. Elghitani F. Dynamic UAV routing for multi-access edge computing. *IEEE Transactions on Vehicular Technology*. 2024. vol. 73. no. 6. pp. 8878–8888. DOI: 1109/TVT.2024.3360253.
11. Dankolo N.M., Radzi N.H.M., Mustaffa N.H., Arshad N.I., Nasser M., Gabi D., Yusuf M.N. Optimizing resource allocation for IoT applications in the edge cloud continuum using hybrid metaheuristic algorithms. *Scientific Reports*. 2024. vol. 15. no. 1. DOI: 10.1038/s41598-025-97648-2.
12. Ismail A.A., Khalifa N.E., El-Khoribi R.A. A survey on resource scheduling approaches in multi-access edge computing environment: A deep reinforcement learning study. *Cluster Computing*. 2025. vol. 28. no. 3. DOI: 10.1007/s10586-024-04893-7.
13. Filianin I., Kapitonov A., Timoshchuk-Bondar A. Gymnasium Library Interface for Multi Access Edge Computing. *Proceedings of 2024 6th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*. 2024. pp. 162–166. DOI: 10.1109/SUMMA64428.2024.10803891.
14. Sun C., Wu X., Li X., Fan Q., Wen J., Leung V.C.M. Cooperative Computation Offloading for Multi-Access Edge Computing in 6G Mobile Networks via Soft Actor Critic. *Proceedings of IEEE Transactions on Network Science and Engineering*. 2021. vol. 11. no. 6. pp. 5601–5614. DOI: 10.1109/TNSE.2021.3076795.
15. Saad M.M., Jamshed M.A., Adedamola A.I., Nauman A., Kim D. Twin Delayed DDPG (TD3)-Based Edge Server Selection for 5G-Enabled Industrial and C-ITS Applications. *IEEE Open Journal of the Communications Society*. 2025. vol. 6. pp. 3332–3343. DOI: 10.1109/OJCOMS.2025.3545566.
16. An L., Wang Z., Yue J., Ma X. Joint Task Offloading and Resource Allocation via Proximal Policy Optimization for Mobile Edge Computing Network. *Proceedings of International Conference on Networking and Network Applications (NaNA)*. 2021. pp. 466–471. DOI: 10.1109/NaNA53684.2021.00087.
17. Zhu L., Tan L., Li B., Tian H. An optimization scheme for vehicular edge computing based on Lyapunov function and deep reinforcement learning. *IET Communications*. 2024. vol. 18. no. 15. pp. 908–924. DOI: 10.1049/cmu2.12800.
18. Facchini C., Holland O., Granelli F., da Fonseca N.L.S., Aghvami H. Dynamic green self-configuration of 3G base stations using fuzzy cognitive maps. *Computer Networks*. 2013. vol. 57. no. 7. pp. 1597–1610. DOI: 10.1016/j.comnet.2013.02.011.
19. Filianin I. Lwmecps-gym. GitHub repository. Available at: <https://github.com/adeptvin1/lwmecps-gym> (accessed 01.08.2025).
20. Filianin I. Lwmecps-testapp. GitHub repository. Available at: <https://github.com/adeptvin1/lwmecps-testapp> (accessed 03.08.2025).
21. Nieto G., de la Iglesia I., Lopez-Novoa U., Perfecto C. Deep Reinforcement Learning techniques for dynamic task offloading in the 5G edge-cloud continuum. *Journal of Cloud Computing*. 2024. vol. 13. no. 1. DOI: 10.1186/s13677-024-00658-0.
22. Haarnoja T., Zhou A., Abbeel P., Levine S. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor. *Proceedings of the 35th International Conference on Machine Learning*. 2018. vol. 80. pp. 1861–1870.
23. Christodoulou P. Soft actor-critic for discrete action settings. *arXiv preprint arXiv:1910.07207*. 2019. DOI: 10.48550/arXiv.1910.07207.
24. Ismail A.A., Khalifa N.E., El-Khoribi R.A. A survey on resource scheduling approaches in multi-access edge computing environment: A deep reinforcement learning study. *Cluster Computing*. 2025. vol. 28. no. 3. DOI: 10.1007/s10586-024-04893-7.

25. Mock J.W., Muknahallipatna S.S. A comparison of PPO, TD3 and SAC reinforcement algorithms for quadruped walking gait generation. *Journal of Intelligent Learning Systems and Applications*. 2023. vol. 15. no. 1. pp. 36–56. DOI: 10.4236/jilsa.2023.151003.

Filianin Ivan — Ph.D. student, Faculty of software engineering and computer systems, ITMO University. Research interests: machine learning algorithms, deep neural networks, reinforcement learning, and their application in decision-making tasks for deploying computing services in geographically distributed data processing nodes, as well as in production optimization tasks. The number of publications — 6. adeptvin1@gmail.com; 49, Kronverksky Ave., 197101, St. Petersburg, Russia; office phone: +7(999)080-3237.

Kapitonov Aleksandr — Ph.D., Associate Professor, Deputy dean, New Uzbekistan University. Research interests: robot economics, blockchain technology applications in robotics, autonomous systems and UAVs, control theory, multi-agent systems, the integration of Large Language Model (LLM) agents in robotic systems. The number of publications — 77. kap2fox@gmail.com; 1, Mavarounnahr, 100000, Tashkent, Uzbekistan; office phone: +7(950)000-2896.

Timoshchuk-Bondar Artem — Software engineer, Faculty of software engineering and computer systems, ITMO University. Research interests: machine learning algorithms, deep neural networks, reinforcement learning, and their application in decision-making tasks for deploying computing services in geographically distributed data processing nodes, as well as in production optimization tasks. The number of publications — 1. artbondar2003@gmail.com; 49, Kronverksky Ave., 197101, St. Petersburg, Russia; office phone: +7(950)517-2406.

И.В. Филянин, А.А. Капитонов, А.И. Тимощук-Бондар

**ИССЛЕДОВАНИЕ АЛГОРИТМОВ ОБУЧЕНИЯ
С ПОДКРЕПЛЕНИЕМ ДЛЯ СНИЖЕНИЯ СЕТЕВОЙ ЗАДЕРЖКИ
В ГРАНИЧНЫХ ВЫЧИСЛЕНИЯХ**

Филянин И.В., Капитонов А.А., Тимощук-Бондар А.И. Исследование алгоритмов обучения с подкреплением для снижения сетевой задержки в граничных вычислениях.

Аннотация. Современные исследования алгоритмов принятия решений в системах multi-access edge computing (MEC) для задач распределения ресурсов зачастую основываются на упрощенных абстракциях сетевой топологии, что ограничивает применимость полученных результатов в реальных условиях эксплуатации мобильных сетей. Целью данной работы является разработка реалистичной модели сети сотовой связи с использованием методов стохастической геометрии и комплексная оценка эффективности современных алгоритмов обучения с подкреплением в задачах минимизации сетевых задержек в граничных вычислениях. Метод. Для создания математически обоснованной модели сетевой среды использовались методы стохастической геометрии в сочетании с реальными статистическими данными распределения пользователей сотовых сетей. Применение стохастической геометрии обеспечило корректное моделирование пространственного размещения базовых станций и расчет межузловых расстояний, критически важных для определения сетевых задержек. Экспериментальная оценка проводилась на базе доработанной платформы LWMECPS с расширенным Gymnasium API, поддерживающим алгоритмы PPO, TD3 и SAC. Основные результаты. Разработана модель сети связи, учитывающая реалистичное пространственное распределение сетевых элементов и временную динамику пользовательской нагрузки. На основе данной модели создано виртуализированное тестовое окружение в LWMECPS, позволяющее проводить воспроизводимые эксперименты с контролируемыми параметрами. Результаты экспериментов показали различия в характеристиках производительности различных алгоритмов: PPO обеспечил стабильное сокращение задержки до 20% со стабильной конвергенцией; SAC продемонстрировал наибольшее абсолютное улучшение (сокращение задержки на 38%), но проявил нестабильность при инициализации; TD3 показал умеренную эффективность (улучшение до 11%), но высокую чувствительность к настройке гиперпараметров. Обсуждение. Проведенный сравнительный анализ алгоритмов машинного обучения с подкреплением выявил ключевые особенности их применения в МЕС-системах. Установлено, что дискретный характер задач размещения сервисов делает алгоритм PPO наиболее подходящим для практического внедрения в системы принятия решений благодаря его стабильности сходимости и естественной поддержке дискретных пространств действий. Полученные результаты предоставляют научно обоснованные рекомендации для разработчиков МЕС-платформ по выбору оптимальных алгоритмических решений.

Ключевые слова: обучение с подкреплением, граничные вычисления с множественным доступом (Multi-Access Edge Computing), оптимизация политики по приближению (Proximal Policy Optimization), Soft Actor-Critic, алгоритм TD3 (Twin Delayed Deep Deterministic Policy Gradient), LWMECPS, Weights & Biases (WandB).

Литература

1. Cruz P., Achir N., Viana A.C. On the edge of the deployment: A survey on multi-access edge computing. *ACM Computing Surveys*. 2022. vol. 55. no. 5. pp. 1–34. DOI: 10.1145/3529758.
2. Yi Y., Zhang G., Jiang H. Mobile Edge Computing Networks: Online Low-Latency and Fresh Service Provisioning. *IEEE Transactions on Communications*. 2025.
3. Wang K., Akhtar S.F., Al-Zahrani F.A. An Efficient Algorithm for Resource Allocation in Mobile Edge Computing Based on Convex Optimization and Karush–Kuhn–Tucker Method. *Complexity*. 2023. vol. 2023(1). pp. 1–15. DOI: 10.1155/2023/9604454.
4. Qin Y., Chen J., Jin L., Yao R., Gong Z. Task offloading optimization in mobile edge computing based on a deep reinforcement learning algorithm using density clustering and ensemble learning. *Scientific Reports*. 2025. vol. 15. no. 1. DOI: 10.1038/s41598-024-84038-3.
5. Rodríguez-Liria A.F., Cárdenas R., Arroba P., Moya J.M., Risco-Martín J.L., Wainer G. Decision Support Framework for Automating the Optimization of Edge Computing Federations. *Proceedings of 2023 Annual Modeling and Simulation Conference (ANNSIM)*. 2023. pp. 49–60.
6. Liu J., Ren J., Zhang Y., Peng X., Zhang Y., Yang Y. Efficient Dependent Task Offloading for Multiple Applications in MEC-Cloud System. *IEEE Transactions on Mobile Computing*. 2021. vol. 22. no. 4. pp. 2147–2162. DOI: 10.1109/TMC.2021.3119200.
7. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Control of multipath transmissions in the nodes of switching segments of reserved paths. *Proceedings of International Conference on Information, Control, and Communication Technologies (ICCT)*. 2022. pp. 1–5.
8. Wang X., Ji Y., Zhang J., Bai L., Zhang M. Low-Latency Oriented Network Planning for MEC-Enabled WDM-PON Based Fiber-Wireless Access Networks. *IEEE Access*. 2019. vol. 7. pp. 183383–183395. DOI: 10.1109/ACCESS.2019.2926795.
9. Ko S.-W., Han K., Huang K. Wireless Networks for Mobile Edge Computing: Spatial Modeling and Latency Analysis. *IEEE Transactions on Wireless Communications*. 2018. vol. 17. no. 8. pp. 5225–5240. DOI: 10.1109/TWC.2018.2840120.
10. Elghitani F. Dynamic UAV routing for multi-access edge computing. *IEEE Transactions on Vehicular Technology*. 2024. vol. 73. no. 6. pp. 8878–8888. DOI: 10.1109/TVT.2024.3360253.
11. Dankolo N.M., Radzi N.H.M., Mustaffa N.H., Arshad N.I., Nasser M., Gabi D., Yusuf M.N. Optimizing resource allocation for IoT applications in the edge cloud continuum using hybrid metaheuristic algorithms. *Scientific Reports*. 2024. vol. 15. no. 1. DOI: 10.1038/s41598-025-97648-2.
12. Ismail A.A., Khalifa N.E., El-Khoribi R.A. A survey on resource scheduling approaches in multi-access edge computing environment: A deep reinforcement learning study. *Cluster Computing*. 2025. vol. 28. no. 3. DOI: 10.1007/s10586-024-04893-7.
13. Filianin I., Kapitonov A., Timoshchuk-Bondar A. Gymnasium Library Interface for Multi Access Edge Computing. *Proceedings of 2024 6th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*. 2024. pp. 162–166. DOI: 10.1109/SUMMA64428.2024.10803891.
14. Sun C., Wu X., Li X., Fan Q., Wen J., Leung V.C.M. Cooperative Computation Offloading for Multi-Access Edge Computing in 6G Mobile Networks via Soft Actor Critic. *Proceedings of IEEE Transactions on Network Science and Engineering*. 2021. vol. 11. no. 6. pp. 5601–5614. DOI: 10.1109/TNSE.2021.3076795.
15. Saad M.M., Jamshed M.A., Adedamola A.I., Nauman A., Kim D. Twin Delayed DDPG (TD3)-Based Edge Server Selection for 5G-Enabled Industrial and C-ITS Applications.

- IEEE Open Journal of the Communications Society. 2025. vol. 6. pp. 3332–3343. DOI: 10.1109/OJCOMS.2025.3545566.
16. An L., Wang Z., Yue J., Ma X. Joint Task Offloading and Resource Allocation via Proximal Policy Optimization for Mobile Edge Computing Network. Proceedings of International Conference on Networking and Network Applications (NaNA). 2021. pp. 466–471. DOI: 10.1109/NaNA53684.2021.00087.
17. Zhu L., Tan L., Li B., Tian H. An optimization scheme for vehicular edge computing based on Lyapunov function and deep reinforcement learning. IET Communications. 2024. vol. 18. no. 15. pp. 908–924. DOI: 10.1049/cmu2.12800.
18. Facchini C., Holland O., Granelli F., da Fonseca N.L.S., Aghvami H. Dynamic green self-configuration of 3G base stations using fuzzy cognitive maps. Computer Networks. 2013. vol. 57. no. 7. pp. 1597–1610. DOI: 10.1016/j.comnet.2013.02.011.
19. Filianin I. Lwmcps-gym. GitHub repository. Available at: <https://github.com/adeptvin1/lwmcps-gym> (accessed 01.08.2025).
20. Filianin I. Lwmcps-testapp. GitHub repository. Available at: <https://github.com/adeptvin1/lwmcps-testapp> (accessed 03.08.2025).
21. Nieto G., de la Iglesia I., Lopez-Novoa U., Perfecto C. Deep Reinforcement Learning techniques for dynamic task offloading in the 5G edge-cloud continuum. Journal of Cloud Computing. 2024. vol. 13. no. 1. DOI: 10.1186/s13677-024-00658-0.
22. Haarnoja T., Zhou A., Abbeel P., Levine S. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor. Proceedings of the 35th International Conference on Machine Learning. 2018. vol. 80. pp. 1861–1870.
23. Christodoulou P. Soft actor-critic for discrete action settings. arXiv preprint arXiv:1910.07207. 2019. DOI: 10.48550/arXiv.1910.07207.
24. Ismail A.A., Khalifa N.E., El-Khoribi R.A. A survey on resource scheduling approaches in multi-access edge computing environment: A deep reinforcement learning study. Cluster Computing. 2025. vol. 28. no. 3. DOI: 10.1007/s10586-024-04893-7.
25. Mock J.W., Muknahallipatna S.S. A comparison of PPO, TD3 and SAC reinforcement algorithms for quadruped walking gait generation. Journal of Intelligent Learning Systems and Applications. 2023. vol. 15. no. 1. pp. 36–56. DOI: 10.4236/jilsa.2023.151003.

Филинин Иван Викторович — аспирант, факультет программной инженерии и компьютерной техники, Университет ИТМО. Область научных интересов: граничные вычисления с множественным доступом, мобильные сети связи. Число научных публикаций — 6. adeptvin1@gmail.com; Кронверкский проспект, 49А, 197101, Санкт-Петербург, Россия; р.т.: +7(999)080-3237.

Капитонов Александр Александрович — канд. техн. наук, доцент, заместитель декана, Новый Университет Узбекистана. Область научных интересов: применение технологий блокчейн в робототехнике, автономные системы и беспилотные летательные аппараты, теория управления, мультиагентные системы и интеграция агентов Large Language Model (LLM) в робототехнических системах.. Число научных публикаций — 77. kap2fox@gmail.com; Мовароуннахра, 1, 100000, Ташкент, Узбекистан; р.т.: +7(950)000-2896.

Тимошук-Бондарь Артем Игоревич — инженер-программист, факультет программной инженерии и компьютерной техники, Университет ИТМО. Область научных интересов: искусственный интеллект, системы принятия решений. Число научных публикаций — 1. artbondar2003@gmail.com; Кронверкский проспект, 49, 197101, Санкт-Петербург, Россия; р.т.: +7(950)517-2406.



XXI-я Всероссийская научно-практическая конференция «ПЕРСПЕКТИВНЫЕ СИСТЕМЫ И ЗАДАЧИ УПРАВЛЕНИЯ»

(«Домбайская конференция»)

6-10 апреля 2026 г.

п. Домбай, Карачаево-Черкесская Республика

Организатором традиционно выступит НИИ робототехники и процессов управления ФГАОУ ВО «Южный федеральный университет» в качестве соорганизаторов конференции выступают: коллегия Военно-промышленной комиссии Российской Федерации, организации Минобороны России, Минпромторга России, МЧС России, МВД России, ФСБ России, Росгвардия, Фонд перспективных исследований, ведущие университеты и институты Минобрнауки России и РАН.

ОСНОВНЫЕ НАПРАВЛЕНИЯ РАБОТЫ СЕКЦИЙ КОНФЕРЕНЦИИ:

- Создание и применение комплексов с БПЛА
- Применение РТК наземного базирования
- Применение РТК морского базирования
- Применение РТК в интересах решения народно-хозяйственных задач
- Групповое применение РТК военного назначения, в т.ч. при взаимодействии с традиционными средствами ВВСТ
- Системы управления и моделирования РТК
- Системы энергетики и приводной техники РТК
- Системы и средства связи, навигации и наведения РТК
- Системы технического зрения и бортовых вычислителей РТК
- Нейроморфные и нейрогибридные системы робототехнических комплексов

Форма проведения: очная и заочная.

ОСНОВНАЯ ЗАДАЧА И НАПРАВЛЕНИЯ РАБОТЫ КОНФЕРЕНЦИИ

Анализ состояния и формирование перспективных направлений развития ключевых технологий создания робототехнических комплексов (РТК) гражданского, военного, специального и двойного назначения и их базовых элементов, ориентированных на повышение их функциональности и расширение перечня задач по применению. С целью вовлечения молодых ученых в области обсуждаемых проблем, развития образовательной и соревновательной сред в рамках конференции запланировано проведение:

- **XVII молодежной школы-семинара «Управление и обработка информации в технических системах»** (ориентировочная дата проведения: 8 апреля 2026 г.) (участники: студенты, магистранты, аспиранты и молодые ученые (возраст до 25 лет включительно))
- **регионального отборочного этапа чемпионата RoboCup Junior** (ориентировочная дата проведения: 8-11 апреля 2026 г.) лига Rescue Line - спасательная линия (участники: школьники и студенты (возраст от 13 лет до 19 лет).

Более подробная информация о конференции и мероприятиях, проводимых в ее рамках, представлена на сайте <http://psct.ru/>.



Наша цель – технологическое превосходство России

Ежегодная всероссийская научная конференция
с международным участием

«Микроэлектронные системы – 2026» (МЭС-2026)

27-28 мая 2026 г.

Кампус Сколковского института науки и технологий (Сколтех)

<https://mesconference.ru>

Главные цели конференции — определение наиболее перспективных направлений исследований с целью обеспечения технологического лидерства России, формирование высокопрофессионального кадрового резерва, создание новых научных и деловых связей.

Учредители-организаторы



Сколтех

Сколковский институт науки и технологий

Альфа-Чип

Инновационный центр



Сколково

Учредители-спонсоры



ГАЗПРОМБАНК



ФОНД
ПЕРСПЕКТИВНЫХ
ИССЛЕДОВАНИЙ



При поддержке ведущих госкорпораций и университетов РФ

Информационные партнеры

ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ

Темы конференции

- Искусственный интеллект в микроэлектронике и микросистемах;
- Фотоника и фотонные интегральные схемы;
- Квантовые технологии в микроэлектронных системах и сенсорах;
- Инновационные методы создания и изготовления микроэлектронных систем;
- Специализированные микроэлектронные системы для роботики, беспилотных систем и космоса.



VI Международная конференция по цифровизации сельского хозяйства и органическому производству

International Conference on Agriculture Digitalization and Organic Production

<http://adop.nw.ru/> 1-5 июня 2026 г. Калининград, Россия

ADOP 2026

ОРГАНИЗАТОРЫ



- Калининградский государственный технический университет (КГТУ, Калининград, Россия)
- Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН, Санкт-Петербург, Россия)



Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

СОПРЕДСЕДАТЕЛИ КОНФЕРЕНЦИИ

Оксана Огий, КГТУ

Андрей Ронжин, СПб ФИЦ РАН

СОПРЕДСЕДАТЕЛЬ ПРОГРАММНОГО КОМИТЕТА

Владимир Суровцев, СПб ФИЦ РАН

ЯЗЫК

Официальным языком конференции является английский и русский.

ВАЖНЫЕ ДАТЫ

- | | |
|----------------|--|
| 1 февраля 2026 | - представление статей |
| 15 марта 2026 | - уведомление о принятии |
| 1 апреля 2026 | - регистрация и подача финальной версии статьи |
| 1-5 июня 2026 | - проведение конференции |

ТРУДЫ КОНФЕРЕНЦИИ

Принятые статьи будут опубликованы в сборнике трудов конференции «Agriculture Digitalization and Organic Production» на английском языке в серии книг *Smart Innovation, Systems and Technologies* издательства Springer, индексируемой в Scopus и Springerlink.



КОНТАКТЫ

Электронная почта: conf@spcras.ru
Сайт конференции: <http://adop.nw.ru/>



Целью конференции является консолидация междисциплинарных знаний в области сельского хозяйства, биологии, робототехники, информационных технологий и экономики для решения актуальных задач цифровизации органического животноводства и растениеводства на основе достижений фундаментальной науки и лучших практик аграрных компаний.

ТЕМАТИКИ

- Органическое сельское хозяйство: организационно-экономические и правовые аспекты
- Рациональные природопользование и экология в сельскохозяйственном производстве
- Робототехника в сельском хозяйстве
- Цифровые технологии и автоматизация в растениеводстве
- Цифровые технологии и автоматизация в животноводстве
- Цифровые технологии и автоматизация в аквакультуре
- Цифровые технологии и устойчивое развитие сельского хозяйства
- Цифровые технологии, производство и рынки органических продуктов

СПЕЦИАЛЬНЫЕ СЕКЦИИ

- Биологизация в животноводстве
- Биологизация в растениеводстве
- Инновации в переработке сельскохозяйственной продукции
- История науки и техники в агропромышленном комплексе
- Цифровая экономика агропромышленного комплекса

ОФОРМЛЕНИЕ СТАТЕЙ

Авторы должны представить свои статьи, используя онлайн-систему подачи заявок: <http://ia.spcras.ru/index.php/adop2026>

Статьи, представленные в оргкомитет, не должны рассматриваться другой конференцией, быть опубликованы ранее или приняться для публикации в другом месте. Авторы должны представить на рецензирование статью на английском языке объёмом 10–12 страниц, отформатированную в стиле издательства Springer.

Принятые статьи должны быть лично представлены на конференции авторами. От одного автора допускается не более двух статей.



**ХI Международная конференция
по интерактивной колаборативной
робототехнике**

<https://icr.nw.ru/>

17-20 августа 2026 г.
Владивосток, Россия



Целью конференции является консолидация знаний в области колаборативного взаимодействия людей и роботов в промышленности, сельском хозяйстве, здравоохранении, образовании и других сферах для создания методов информационного и физического совместного взаимодействия водных, наземных и воздушных роботов, операторов и неподготовленных пользователей в недетерминированных средах.

ОРГАНИЗАТОРЫ

- Институт автоматики и процессов управления Дальневосточного отделения Российской академии наук (ИАПУ ДВО РАН, Владивосток, Россия)
- Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН, Санкт-Петербург, Россия)

СОПРЕДСЕДАТЕЛИ КОНФЕРЕНЦИИ

- Роман Ромашко, ИАПУ ДВО РАН
- Андрей Ронжин, СПб ФИЦ РАН

ОФОРМЛЕНИЕ СТАТЕЙ

Авторы должны представить свои статьи, используя онлайн-систему подачи заявок: <http://ia.spcras.ru/index.php/icr2026>.

Статьи, представленные в оргкомитет, не должны рассматриваться другой конференцией, быть опубликованы ранее или приняты для публикации в другом месте. Авторы должны представить на рецензирование статью на английском языке объемом 12–15 страниц, отформатированную в стиле издательства Springer.

Принятые статьи должны быть лично представлены на конференции авторами. От одного автора допускается не более двух статей.

КОНТАКТЫ

E-mail: conf@spcras.ru
Web: <https://icr.nw.ru/>

ТЕМАТИКА

- Автономный беспилотный транспорт
- Ассистивная робототехника
- Безопасность робототехнических систем
- Бытовая робототехника
- Коллаборативная робототехника
- Медицинская робототехника
- Образовательная робототехника
- Сервисные роботы
- Технологии искусственного интеллекта
- Управление робототехническими системами

ЯЗЫК

Официальным языком конференции является английский.

ВАЖНЫЕ ДАТЫ

- 1 апреля 2026 - представление статей
- 15 мая 2026 - уведомление о принятии
- 1 июня 2026 - регистрация и подача финальной версии статьи
- 17-20 августа 2026 - проведение конференции

ТРУДЫ КОНФЕРЕНЦИИ

Принятые статьи будут опубликованы в сборнике трудов конференции «Interactive Collaborative Robotics» на английском языке в серии книг LNCs (LNAI) издательства Springer, индексируемой в SCOPUS (Q2) и Springerlink.



XII ВСЕРОССИЙСКАЯ НАУЧНО-ПРАКТИЧЕСКАЯ КОНФЕРЕНЦИЯ «ПЕРСПЕКТИВНЫЕ НАПРАВЛЕНИЯ РАЗВИТИЯ ОТЕЧЕСТВЕННЫХ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ (ПИРОИТ-2026)»

Севастополь, 22-26 сентября 2026 г.



УВАЖАЕМЫЕ КОЛЛЕГИ!

Приглашаем Вас принять участие в работе XII Всероссийской научно-практической конференции «Перспективные направления развития отечественных информационных технологий (ПИРОИТ-2026)», которая состоится 22-26 сентября 2026 г. в г. Севастополе на базе Севастопольского государственного университета.

Учредители Конференции: Министерство науки и высшего образования Российской Федерации, Правительство Севастополя, Законодательное Собрание Севастополя, Правительство Санкт-Петербурга, Севастопольский государственный университет, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Крымский ИТ-клUSTER.

Планируется обсуждение приоритетных направлений развития отечественных информационных технологий, обеспечения технологического суверенитета в ИТ-сфере в условиях внешнего санкционного давления, цифровой трансформации отраслей экономики и социальной сферы, а также взаимодействия представителей органов государственной власти, научно-образовательных организаций и бизнеса по вопросам реализации государственной информационной политики, направленной на поддержку секторов отечественной ИТ-индустрии, сохранение и развитие кадрового потенциала предприятий высокотехнологичных отраслей промышленности, привлечение молодежи в ИТ-сферу, создание комфортных условий ведения ИТ-бизнеса в России.

Планируются дискуссии по проблемам совершенствования региональной информационной и телекоммуникационной инфраструктуры, создания и внедрения отечественных цифровых платформ, достижения технологического лидерства в отечественном ИТ-секторе, обеспечения информационной безопасности, интеграции Севастополя и Республики Крым в образовательное и информационное пространство России, подготовки и переподготовки ИТ-специалистов.

НАПРАВЛЕНИЯ РАБОТЫ КОНФЕРЕНЦИИ

- Информатика, вычислительная техника и искусственный интеллект;
- Фундаментальные проблемы развития информационных технологий;
- Искусственный интеллект и технологии «Умного города»;
- Информационные среды и телекоммуникационная инфраструктура;
- Информационные технологии в критических инфраструктурах. Информационная безопасность;
- Информационные технологии в машиностроении;
- Информационные технологии в морехозяйственной деятельности;
- Геоинформационные системы и спутниковый мониторинг;
- ИТ-продукты и услуги. Технологический суверенитет в ИТ-сфере;
- ИТ в образовании, подготовка и переподготовка ИТ-специалистов.

Программа Конференции включает проведение пленарного и секционных заседаний, организацию телемоста Севастополь – Санкт-Петербург – Москва, учебных семинаров, презентаций, курсов повышения квалификации, организации выставочных площадок и круглых столов для обмена опытом и взаимодействия ученых, преподавателей вузов, руководителей и специалистов ИТ-компаний, представителей органов власти, бизнес-сообщества и профессиональных общественных организаций.

В рамках Конференции планируется проведение выездного заседания Федерального УМО в системе высшего образования по укрупненной группе специальностей и направлений высшего образования 09.00.00 «Информатика и вычислительная техника».

Подробная информация на сайте: <https://pnoit.sevsu.ru/>

УСЛОВИЯ УЧАСТИЯ В КОНФЕРЕНЦИИ

Для участия в Конференции необходимо зарегистрироваться, заполнив анкету на сайте: <https://pnoit.sevsu.ru/> или переслав её по адресу: pnoit_conf@mail.ru, и после получения уведомления о включении доклада в Программу Конференции перечислить организационный целевой взнос.

Оргкомитетом Конференции планируется издание сборника докладов, который будет размещен в научной электронной библиотеке e-library и проиндексирован в РИНЦ. Авторам лучших докладов будут вручены сертификаты участников Конференции и даны рекомендации по опубликованию результатов проводимых ими исследований в периодических научных изданиях.

Публикуемые материалы докладов должны быть подготовлены в соответствии с требованиями к оформлению. Прием материалов докладов осуществляется до 31 июля 2026 г. Заявки на участие в Конференции без публикации принимаются до 11 сентября 2026 г.



**ЮБИЛЕЙНАЯ XX САНКТ-ПЕТЕРБУРГСКАЯ МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ
«РЕГИОНАЛЬНАЯ ИНФОРМАТИКА (РИ-2026)»**
Санкт-Петербург, 28-30 октября 2026 г.

Информационное письмо № К-1/2026

Уважаемые господа!

Приглашаем Вас принять участие в работе юбилейной XX Санкт-Петербургской международной конференции «Региональная информатика (РИ-2026)», учрежденной в 1992 году, которая состоится в Санкт-Петербурге при поддержке Правительства Санкт-Петербурга в период **28-30 октября 2026 года**.

УЧРЕДИТЕЛИ КОНФЕРЕНЦИИ

Правительство Санкт-Петербурга, Законодательное Собрание Санкт-Петербурга, Правительство Ленинградской области, Министерство науки и высшего образования РФ, Министерство цифрового развития, связи и массовых коммуникаций РФ, Российская академия образования, Отделение нанотехнологий и информационных технологий Российской академии наук, Санкт-Петербургское отделение Российской академии наук и др.

ТЕМАТИЧЕСКИЕ НАУЧНЫЕ НАПРАВЛЕНИЯ

- Государственная политика информатизации
- Теоретические проблемы информатики и информатизации
 - Телекоммуникационные сети и технологии
 - Информационная безопасность
 - Правовые проблемы информатизации
 - Круглый стол «Информационно-аналитическое обеспечение органов государственной власти»
 - Информационно-психологическая безопасность
 - Информационные технологии в экономике
 - Круглый стол «Информационные технологии в критических инфраструктурах»
 - Информационные технологии на транспорте
 - Информационные технологии в образовании
 - Информационные технологии в медицине и здравоохранении
 - Информационные технологии управления объектами морской техники и морской инфраструктуры
 - Информационные технологии в дизайне, печати и медиаиндустрии
 - Геоинформационные системы
 - Информационные технологии в социокомпьютеинге
 - Молодежная научная школа «Экосистема городских цифровых сервисов»
 - Молодежная научная школа «Безопасные интеллектуальные информационные системы и технологии»
 - Молодежная научная школа «Безопасные системы связи»
 - Научная школа молодых ученых «Информационные технологии и моделирование»
 - Круглый стол «Обеспечение информационной безопасности РИУ»
 - Круглый стол «Подготовка разработчиков информационных систем и технологий в Российской высшей школе»

УСЛОВИЯ УЧАСТИЯ В КОНФЕРЕНЦИИ

Для участия в работе конференции необходимо зарегистрироваться в базе данных конференции, указать наименование выбранного научного направления на сайте: <http://spoisu.ru/conf/ri2026>, приложить тезисы

(материалы) доклада и (или) научную статью и указать сведения о перечислении организационного целевого взноса участника конференции (номер и дату платежного поручения, квитанции банка и т.л.). Правила и примеры оформления тезисов докладов и статей размещены на сайте: <http://spoisu.ru/conf/ri2026>

Тезисы докладов, поступившие в срок не позднее **31» июля 2026 г.** и одобренные Программным комитетом, будут опубликованы к началу конференции в сборнике материалов, индексированном в РИНЦ. Одобренные статьи будут опубликованы в выпуске № 15 периодического издания «Региональная информатика и информационная безопасность», индексированном в РИНЦ, после проведения конференции. Оргкомитет оставляет за собой право не публиковать материалы, авторы которых представили материалы с нарушением установленных сроков и правил оформления.

**ФИНАНСИРОВАНИЕ ПОДГОТОВКИ
И ПРОВЕДЕНИЯ КОНФЕРЕНЦИИ**

Подготовка и проведение конференции «РИ-2026» осуществляется при поддержке Правительства Санкт-Петербурга с привлечением организационных целевых взносов (добровольных пожертвований) предприятий-содружеств конференции.

Минимальный размер организационного целевого взноса на подготовку и проведение конференции составляет 3000 руб.

В соответствии со сметой указанные средства расходуются на софинансирование подготовки и проведения конференции. Проживание в гостинице и питание участники оплачивают самостоятельно.

В платежном поручении следует указать:

Получатель: СПОИСУ. Р/с 407038106270000003078
в ПАО «Банк «Санкт-Петербург» к/с 30101810900000000790
БИК 04403790 ИНН 7813148260 КПП 781301001

Назначение платежа: Организационный целевой взнос (добровольное пожертвование) на подготовку и проведение конференции «РИ-2026» согласно информационному письму № К-1/2026, (ФИО представителя). НДС не облагается.

**МЕСТО ПРОВЕДЕНИЯ КОНФЕРЕНЦИИ
И КОНТАКТЫ ОРГКОМИТЕТА**

Торжественное открытие конференции состоится **«28» октября 2026 года в 10:00 часов** в Белом зале Дома ученых им. М. Горького по адресу: Санкт-Петербург, Дворцовая наб., д. 26.

Начало регистрации гостей и участников с 9:30 часов.

Почтовый адрес Оргкомитета конференции:

199178, Санкт-Петербург, В.О., 14-я линия, д. 39.

Санкт-Петербургский Федеральный исследовательский центр Российской академии наук

Регистрация участников, прием материалов для опубликования, оперативная связь с Оргкомитетом:
e-mail: ri@spoisu.ru (регистрация), spoisu@mail.ru
моб. тел.: +7 (921) 188-93-15, тел./факс: (812) 328-33-11
<http://spoisu.ru/conf/ri2026>

Руководство для авторов

Взаимодействие автора с редакцией осуществляется через личный кабинет на сайте журнала «Информатика и автоматизация» <http://ia.spcras.ru/>. При регистрации авторам рекомендуется заполнить все предложенные поля данных. Подготовка статьи ведется с помощью текстовых редакторов MS Word 2007 и выше или LaTex. Объем основного текста (до раздела Литература) - от 20 до 30 страниц включительно. Переносы запрещены. Номера страниц не проставляются. Основная часть текста статьи разбивается на разделы, среди которых являются обязательными: введение, хотя бы один «содержательный» раздел и заключение. Допускается также мотивированное содержанием и структурой материал а выделение подразделов. В основную часть опускается помещать рисунки, таблицы, листинги и формулы. Правила их оформления подробно рассмотрены на нашем сайте в разделе «Руководство для авторов».

Author guidelines

Interaction between each potential author and the Editorial board is realized through the personal account on the website of the journal "Informatics and Automation" <http://ia.spcras.ru/>. At the registration the authors are requested to fill out all data fields in the proposed form. The submissions should be prepared using MS Word 2007, LaTex. The text of the paper in the main part should not exceed 30 pages. Pages are not numbered; hyphenations are not allowed. Certain figures, tables, listings and formulas are allowed in the main section, and their typography is considered in more detail at the journal web.

Signed to print 03.02.2026. Passed for print 04.02.2026.

Printed in Publishing center GUAP.

Address: 67 litera A, B. Morskaya, St. Petersburg, 190000, Russia

Founder and Publisher: SPC RAS.

Address: 39 litera A, 14th Line V.O., St.Peterburg, 199178, Russia.

The journal is registered in the Federal Service for Supervision of Communications,
Information Technology, and Mass Media,

Registration Certificate (registration number) ПИ № ФС77-79228 dated September 25, 2020
Subscription Index П5513, Russian Post Catalog

Подписано к печати 03.02.2026. Дата выхода в свет 04.02.2026.

Формат 60×90 1/16. Усл. печ. л. 15,6. Заказ № 11. Тираж 300 экз., цена свободная.

Отпечатано в Редакционно-издательском центре ГУАП.

Адрес типографии: Б. Морская, д. 67, лит. А, г. Санкт-Петербург, 190000, Россия

Учредитель и издатель: СПб ФИЦ РАН.

Адрес учредителя и издателя: 14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

Журнал зарегистрирован Федеральной службой по надзору в сфере связи,

информационных технологий и массовых коммуникаций,

свидетельство о регистрации (регистрационный номер) ПИ № ФС77-79228 от 25 сентября 2020 г.

Подписной индекс П5513 по каталогу «Почта России»